

DOKTORI (PhD) ÉRTEKEZÉS

VANCSURA LÁSZLÓ

Kaposvár

2025



MAGYAR AGRÁR- ÉS ÉLETTUDOMÁNYI EGYETEM

**A GÉPI TANULÁSI MODELLEK SZEREPE A GAZDASÁGI ÉS TŐZSDEI
IDŐSOROK ELŐREJELZÉSÉBEN**

DOI: 10.54598/005800

DOKTORI (PhD) ÉRTEKEZÉS

VANCSURA LÁSZLÓ

**Kaposvár
2025**

A doktori iskola megnevezése: Gazdaság- és Regionális Tudományok Doktori Iskola

A doktori iskola tudományága: gazdaság- és regionális tudományok

A doktori iskola vezetője: Prof. Dr. habil Bujdosó Zoltán
egyetemi tanár
Magyar Agrár- és Élettudományi egyetem
Vidékfejlesztés és Fenntartható Gazdaság Intézet

Témavezető: Dr. Bareith Tibor
tudományos munkatárs
ELTE Közgazdaság- és Regionális Tudományi
Kutatóközpont
Közgazdaságtudományi Intézet

.....
Az iskolavezető jóváhagyása

.....
A témavezető(k) jóváhagyása

TARTALOMJEGYZÉKJELÖLÉSEK, RÖVIDÍTÉSEK JEGYZÉKE	
1. BEVEZETÉS.....	1
2. SZISZTEMATIKUS SZAKIRODALMI ÁTTEKINTÉS	5
2.1. Bevezetés.....	5
2.2. A mesterséges intelligencia alkalmazhatósága a pénzügyekben	6
2.2.1. Pénzügyi piacok és hatékonyság	6
2.2.2. Alternatív adatok és információs hatékonyság	8
2.2.3. Kockázatkezelés és pénzügyi stabilitás	9
2.2.4. Portfóliókezelés és eszközallokáció	9
2.2.5. Eszközárazás	10
2.3. A szisztematikus szakirodalmi áttekintés módszertana	12
2.4. Szakirodalmi adatbázis elemzésének eredményei.....	15
2.5. A vizsgált piacok szakirodalmának ismertetése	20
2.5.1. Részvénypiaci előrejelzések.....	20
2.5.2. Árupiaci előrejelzések	28
2.5.3. Kriptovaluta előrejelzések.....	34
2.5.4. Devizapiaci előrejelzések	41
2.6. Szisztematikus szakirodalmi áttekintés összegzése.....	46
2.7. Kutatási rések azonosítása.....	47
2.8. Az előrejelző modellek kereskedési stratégiákban történő alkalmazása	48
2.9. Szakirodalmi áttekintés a volatilitás és az előrejelző modellek teljesítményének kapcsolatáról	53
2.9.1. Rezsimváltó mechanizmusok alkalmazása, avagy adaptáció a változó piaci körülményekhez	54
2.9.2. A releváns volatilitási információk fókuszált figyelembevétele az előrejelző modellekben	57
2.10. A vizsgált időszak (2016–2022) globális pénzügyi és gazdaságpolitikai, sajátosságai, valamint ezek hatása a pénzügyi piacokra	60
3. CÉLKITŰZÉSEK.....	63
4. ANYAG ÉS MÓDSZER	66
4.1. Adatok	66
4.2. Alkalmazott módszerek	70
4.2.1. Simple Recurrent Neural Network (RNN)	70
4.2.2. Gated Recurrent Unit (GRU)	70
4.2.3. Long-Short Term Memory (LSTM)	71
4.2.4. LSTM-GRU hibrid	72
4.2.5. RNN-LSTM hibrid	73
4.2.6. RNN-GRU hibrid	73
4.3. Az alkalmazott szoftverek és programterv	73
4.4. A modellek értékelése.....	75
4.5. Hiperparaméterek	76
4.6. Adatbázis felosztás, keresztvalidáció és túlillesztés.....	76

4.6.1. Keresztvalidáció	77
4.6.2. Túlillesztés.....	78
4.7. Aktivációs függvények	78
4.7.1. ReLU	79
4.7.2. Sigmoid	80
4.7.3. Tanh	80
4.8. Volatilitás vizsgálata	80
4.8.1. STL (Seasonal-Trend decomposition using Loess)	80
4.8.2. Relatív volatilitás: variációs koefficiens (CV)	81
4.9. Predikció alapú, dinamikusan optimalizált kereskedési stratégia.....	81
5. EREDMÉNYEK.....	84
5.1. Terméktípusok szerinti eredmények	86
5.1.1. Részvénypiac.....	86
5.1.2. Árupiac	92
5.1.3. Kriptovaluta piac	96
5.1.4. Devizapiac	100
5.2. Termékek közötti összehasonlítás	104
5.3. Modellenkénti összteljesítmény összehasonlítás.....	110
5.4. Abszolút legjobb és legrosszabb eredmények	116
5.5. Aktivációs függvény-optimalizálás	121
5.6. Volatilitás vizsgálatának eredményei.....	124
5.7. Kereskedési stratégiák eredményeinek összehasonlítása	133
6. KÖVETKEZTETÉSEK ÉS JAVASLATOK.....	142
7. ÚJ TUDOMÁNYOS EREDMÉNYEK.....	147
8. ÖSSZEFOGLALÁS	150
9. SUMMARY.....	153
10. MELLÉKLETEK	156
M1. Irodalomjegyzék	156
M2. Ábrajegyzék.....	181
M3. Táblázatok jegyzéke.....	183
M4. További mellékletek.....	184
KÖSZÖNETNYILVÁNÍTÁS	202

JELÖLÉSEK, RÖVIDÍTÉSEK JEGYZÉKE

Rövidítés	Teljes elnevezés
LR	Linear Regression (lineáris regresszió)
BLR	Bayesian Linear Regression (Bayes-i lineáris regresszió)
DT	Decision Tree (döntési fa)
RF	Random Forest (véletlenszerű erdő)
ELM	Extreme Learning Machine (extrém tanulási gép)
Adaboost	Adaptive Boosting Regression (adaptív erősítésű regresszió)
Gredient Boost	Gradient Boosting Regression (gradiens erősítésű regresszió)
XGBoost	Extreme Gradient Boosting (extrém gradiens erősítés)
LightGBM	Light Gradient Boosting Machine (laza gradiens erősítés)
SVR	Support Vector Regression (támaszvektor regresszió)
ABC-SVR	Artificial Bee Colony - Support Vector Regression (mesterséges méhkolónia – támaszvektor regresszió)
SSA-SVR	Strategic Seasonality-Adjusted - Support Vector Regression (stratégiai szezonalitással kiigazított – támaszvektor regresszió)
OGA-SVR	Optimized Genetic Algorithm-based - Support Vector Regression (optimalizált genetikusan alapú – támaszvektor regresszió)
FS-GA-SVR	Feature Selection - Genetic Algorithm - Support Vector Regression (genetikusan optimalizált változókiválasztásos – támaszvektor regresszió)
WAMC	Weighted Memory Channels Regression (súlyozott memóriacsatorna regresszió)
ANFIS	Adaptive Network Fuzzy Inference System (adaptív hálózati fuzzy inferenciarendszer)
TDNN	Time-Delay Neural Network (időben késleltetett neurális hálózat)
GINN	Generalized Improved Neural Network (általános javított neurális hálózat)
DNPP	Dynamic Noisy Proximal Policy (dinamikusan zajmentesített közelítő irányelv)
DBN	Deep Belief Network (mély meggyőződési hálózat)
GVMD-Q-DBN-LSTM-GRU	Generalized Variational Mode Decomposition - Q-learning algorithm - Deep Belief Network - Long Short-term Memory - Gated Recurrent Unit (általánosított variációs módusz szétbontás – q tanulási algoritmus - mély meggyőződési hálózat - hosszú rövid-távú memória - rekurrens neurális hálózat)
KNN	K-Nearest Neighbors (K legközelebbi szomszédság)
KNN-XGB-SVR	K-Nearest Neighbors – Extreme Gradient Boosting - Support Vector Regression (K legközelebbi szomszédság - extrém gradiens erősítés - támaszvektor regresszió)
ENN	Elman Neural Network (Elman neurális hálózat)
ANN	Artificial Neural Networks (mesterséges neurális hálózatok)
DNN	Deep Neural Network (mély neurális hálózat)
RNN	Recurrent Neural Network (rekurrens neurális hálózat)
BSd-RNN	B-spline - Recurrent Neural Network (b-spline függvénnel optimalizált – rekurrens neurális hálózat)
DWT-RNN	Discrete Wavelet Transform - Recurrent Neural Network (diszkrét hullám transzformáció – rekurrens neurális hálózat)
CNN	Convolutional Neural Network (összefonódásos neurális hálózat)
CNN-RNN	Convolutional Neural Network - Recurrent Neural Network (összefonódásos neurális hálózat - rekurrens neurális hálózat)
TCN	Temporal Convolutional Network (ideiglenes összefonódású hálózatok)
GRU	Gated Recurrent Unit (kapcsolható rekurrens egység)
LSTNet	Long- and Short-Term Time-series Network (hosszú rövid-távú idősoros hálózat)
LSTM	Long Short-term Memory (hosszú rövid-távú memória)
LSTM-GRU	Long Short-term Memory - Gated Recurrent Unit (hosszú rövid-távú memória - rekurrens neurális hálózat)

Rövidítés	Teljes elnevezés
GRU-LSTM	Gated Recurrent Unit - Long Short-term Memory (rekurrens neurális hálózat - hosszú rövid-távú memória)
BiLSTM	Bidirectional Long Short-term Memory (kétirányú hosszú rövid-távú memória)
BiLSTM-BR	Bidirectional Long Short-term Memory - Bagging Ridge (kétirányú hosszú rövid-távú memória – csomagoló ridge)
SLSTM	Stacked Long Short-term Memory (halmozott hosszú rövid-távú memória)
LSTM-DNN	Long Short-term Memory - Deep Neural Network (hosszú rövid-távú memória - mély neurális hálózat)
XGBoost-LSTM	Extreme Gradient Boosting - Long Short-term Memory (extrém gradiens erősítés - hosszú rövid-távú memória)
CNN-Bi-LSTM-AM	Convolutional Neural Network - Bidirectional Long Short-term Memory - Attention Mechanism (összefonódásos neurális hálózat - kétirányú hosszú rövid-távú memória - figyelem mechanizmus)
SFM	State Frequency Memory (állapot frekvencia memória)
GA	Genetic Algorithms (genetikus algoritmus)
MLP	Multilayer Perceptron (többretegű érzékelés)
CNN-LSTM	Convolutional Neural Network - Long Short-term Memory (összefonódásos neurális hálózat - hosszú rövid-távú memória)
LSTM-CNN	Long Short-term Memory - Convolutional Neural Network (hosszú rövid-távú memória - összefonódásos neurális hálózat)
LSTM-ARO	Long Short-term Memory - Artificial Rabbits Optimization (hosszú rövid-távú memória – mesterséges nyúl otpimalizálás)
DC-LSTM	Deep Coupled - Long Short-term Memory (mélyen összekapcsolt - hosszú rövid-távú memória)
GWO-CNN-LSTM	Gray Wolf Optimizer - Convolutional Neural Network - Long Short-term Memory (szürke farkas optimalizálás - összefonódásos neurális hálózat - hosszú rövid-távú memória)
CNN-GRU	Convolutional Neural Network - Gated Recurrent Unit (összefonódásos neurális hálózat - kapcsolható rekurrens egység)
EMD-CNN-GRU	Empirical Mode Decomposition - Convolutional Neural Network - Gated Recurrent Unit (empirikus módusz szétbontás - összefonódásos neurális hálózat - kapcsolható rekurrens egység)
VMD-CNN-GRU	Variational Mode Decomposition - Convolutional Neural Network - Gated Recurrent Unit (variációs módusz szétbontás - összefonódásos neurális hálózat - kapcsolható rekurrens egység)
AR	Autoregressive (autoregresszió)
AR-DNN	Autoregressive - Deep Neural Network (autoregresszió – mély neurális hálózat)
ARIMA	AutoRegressive Integrated Moving Average (autoregresszív integrált mozgó átlag)
VAR	Vector Auto-Regression (vektor autoregresszió)
GARCH	Generalized Autoregressive Conditional Heteroskedasticity (általánosított autoregresszív feltételes heteroszkedaszticitás)
APGARCH	Asymmetric Power Generalized Autoregressive Conditional Heteroskedasticity (aszimmetrikus teljesítmény általánosított autoregresszív feltételes heteroszkedaszticitás)
WT-LSTM	Wavelet Transform - Long Short-term Memory (hullám transzformáció - hosszú rövid-távú memória)
WT-GRU	Wavelet Transform - Gated Recurrent Unit (hullám transzformáció - kapcsolható rekurrens egység)
WT-TCN	Wavelet Transform - Temporal Convolutional Network (hullám transzformáció - ideiglenes összefonódású hálózatok)
LSTM-RL	Long Short-term Memory - Reinforcement Learning (hosszú rövid-távú memória – megerősítő tanulás)
HMM-ALSTM	Hidden Markov Model - Attentive Long Short-term Memory (rejtett Markov model - figyelmes hosszú rövid-távú memória)

Rövidítés	Teljes elnevezés
RMT-LSTM	Removing outliers Mahalanobis Transformation - Long Short-term Memory (kiugró érték eltávolító Mahalanobis transzformáció - hosszú rövid-távú memória)
RZT-LSTM	Removing outliers Z-score Transformation - Long Short-term Memory (kiugró érték eltávolító Z-score transzformáció - hosszú rövid-távú memória)
ANN-GARCH	Artificial Neural Networks - Generalized Autoregressive Conditional Heteroskedasticity (mesterséges neurális hálózatok - általánosított autoregresszív feltételes heteroszkedaszticitás)
ANN-GJR	Artificial Neural Networks - Glosten, Jagannathan, and Runkle (mesterséges neurális hálózatok – Glosten, Jagannathan és Runkle)
CEEMDAN-LSTM	Complete Ensemble Empirical Mode Decomposition Adaptive Noise - Long Short-term Memory (zajokhoz alkalmazkodó teljeskörű empirikus módusz szétbontás - hosszú rövid-távú memória)
CEEMDAN-SVR	Complete Ensemble Empirical Mode Decomposition Adaptive Noise - Support Vector Regression (zajokhoz alkalmazkodó teljeskörű empirikus módusz szétbontás - támaszvektor regresszió)
CEEMDAN-MLP	Complete Ensemble Empirical Mode Decomposition Adaptive Noise - Multilayer Perceptron (zajokhoz alkalmazkodó teljeskörű empirikus módusz szétbontás - többretegű érzékelés)
CEEMDAN-GRU	Complete Ensemble Empirical Mode Decomposition Adaptive Noise - Gated Recurrent Unit (zajokhoz alkalmazkodó teljeskörű empirikus módusz szétbontás - kapcsolható rekurrens egység)
CEEMDAN-CNN	Complete Ensemble Empirical Mode Decomposition Adaptive Noise - Convolutional Neural Network (zajokhoz alkalmazkodó teljeskörű empirikus módusz szétbontás - összefonódásos neurális hálózat)
CEEMDAN-CNN-GRU	Complete Ensemble Empirical Mode Decomposition Adaptive Noise - Convolutional Neural Network - Gated Recurrent Unit (zajokhoz alkalmazkodó teljeskörű empirikus módusz szétbontás - összefonódásos neurális hálózat - kapcsolható rekurrens egység)
CEEMDAN-TCN	Complete Ensemble Empirical Mode Decomposition Adaptive Noise - Temporal Convolutional Network (zajokhoz alkalmazkodó teljeskörű empirikus módusz szétbontás - ideiglenes összefonódású hálózatok)
MEMD-GRU	Multivariate Empirical Mode Decomposition - Gated Recurrent Unit (többváltozós empirikus módusz szétbontás - kapcsolható rekurrens egység)
MEMD-TCN	Multivariate Empirical Mode Decomposition - Temporal Convolutional Network (többváltozós empirikus módusz szétbontás - ideiglenes összefonódású hálózatok)
CATN	Cross Attentive Tree-aware Network (keresztfigyelmű fa-alapú hálózat)
ICEEMDAN-LSTM-CNN-CBAM	Improved Complete Ensemble Empirical Mode Decomposition Adaptive Noise - Long Short-term Memory - Convolutional Neural Network - Convolutional Block Attention Module (továbbfejlesztett zajokhoz alkalmazkodó teljeskörű empirikus módusz szétbontás - hosszú rövid-távú memória - összefonódásos neurális hálózat - összefonódó blokkos figyelem modul)
DWT-FFNN	Discrete Wavelet Transform - Feed-Forward Neural Network (diszkrét hullám transzformáció - előcsatlakoztatott neurális hálózat)
WNN	Wavelet Neural Network (hullám neurális hálózat)
GRNN	Generalized Regression Neural Networks (általánosított regresszív neurális hálózatok)
FFNN	Feed-Forward Neural Network (előcsatlakoztatott neurális hálózat)

1. BEVEZETÉS

A tőzsde és a pénzügyi termékek iránt az érdeklődés az átlagemberek részéről az elmúlt évtizedekben exponenciálisan nőtt (Kumbure et al., 2022). A világ tőzsdéin naponta több milliárd dollár értékű eszköz cserél gazdát (Hoseinzade és Haratizadeh, 2019), a befektetők pedig azzal a szándékkal lépnek fel a piacon, hogy befektetési horizontjuk alatt nyereséget érjenek el. Ha egy magán- vagy intézményi befektető pontosan meg tudná jósolni a piac viselkedését és mozgásait, akkor ez lehetővé tenné számára, hogy magasabb kockázattal korrigált hozamot (alpha) érjen el, mint a piac. Többek között ez a tényező is motiválja a gépi tanulás és a számítógépes intelligencia módszereinek alkalmazását a tőzsdei előrejelzés minél pontosabb modelljeinek létrehozására, illetve a már meglévők finomhangolására. A részvény- és más pénzügyi piacok előrejelezhetőségét számos tanulmány vizsgálta már kifinomult előrejelző rendszerek kifejlesztésével (Sedighi et al., 2019; Song et al., 2019), közülük néhány tanulmány arról is beszámolt, hogy modelljeik komoly nyereséget tudtak termelni (Atsalakis & Valavanis, 2009a; Weng et al., 2017).

Általánosságban elmondható, hogy a tőzsdei előrejelzést a pénzügyi kutatás egyik legrelevánsabb, ugyanakkor kihívásokkal teli területeként kezelik (Chen és Hao, 2017). Mindazonáltal az a képesség, hogy egy befektető folyamatosan magasabb kockázattal korrigált hozamot ér el, mint a piac, sértheti az úgynevezett hatékony piacok hipotézisét. Fama (1970) nevéhez fűződik a piaci hatékonyság hipotézise (EMH – Efficient Market Hypothesis). Az EMH a piaci hatékonyság három formáját különbözteti meg. A gyenge formájú piaci hatékonyság azt feltételezi, hogy az idősor múltbeli áraiban szereplő információk már tükröződnek az aktuális részvényárakban is és nem segítenek a jövőbeli árfolyam-mozgások előrejelzésében (Fama, 1970). Ebből kifolyólag a technikai elemzés nem tud a várható hozam tekintetében felülmúlni egy buy-and-hold stratégiát. A hatékony piacok hipotézisének második formája az úgynevezett félig erős piaci hatékonyság, amely azt állítja, hogy a részvényárak az összes nyilvánosan elérhető információt tükrözik (gazdasági körülmények, politikai események, kamatláb és vállalatspecifikus információk, stb.), amelyek magában foglalják a múltbeli árakra vonatkozó információkat is. Mindez arra utal, hogy a technikai elemzés eszköztárát alkalmazva sem lehet következetesen magasabb várható hozamot realizálni. A piaci hatékonyság félig erős formája esetén a nyilvánosan elérhető információk - beleértve a fundamentális adatokat is - tehát nem teszik lehetővé, hogy egy befektető felülmúlja a piacot. Ez azt jelenti, hogy az összes nyilvánosan elérhető információ birtokában az aktívan menedzselt portfóliók nem fognak következetesen magasabb kockázattal korrigált hozamot elérni, mint a passzívok, azaz a buy-and-hold stratégiát követők. Az EMH harmadik, erős formája azt állítja, hogy minden információ, beleértve a bennfentes információkat is, tükröződik a részvényárakban. Ez pedig kizárja azt, hogy bármely befektető (rendelkezzen akár bennfentes

információkkal is) következetesen magasabb várható hozamot érjen el, mint a piac (Fama, 1965). Ezen okból kifolyólag az EMH erős formája gyakorlatilag azt állítja, hogy a részvénytársasági árfolyamok alakulása, illetve a hozamok nem jelezhetők előre (Timmermann és Granger, 2004). Az EMH erős formája rendkívül szigorú kritériumokra épül, melyeket később maga Fama (1970) is részben megcáfolt, illetve finomított. Úgy fogalmazott, hogy nem várható el, hogy a bennfentes információk nem használhatók fel a magasabb várható profit realizálása érdekében.

Idővel egyre többen kérdőjelezték meg a hatékony piacok hipotézisét és azt, hogy az értékpapírok árazása racionálisan történik (Daniel et al., 1998; Borovkova és Tsiamas, 2019). Számos olyan piaci anomália létezik, amely a hatékony piacok hipotézise ellen szól (Malkiel és Mullainathan, 2005). Ilyenek például a pénzügyi piacok túlreagálása (De Bondt és Thaler, 1985) és alulreagálása, a rövid távú lendület, a hosszú távú visszafordulás és az eszközárak magas volatilitása. Egyes kutatók az ilyen anomáliáknak a hatékony piacok hipotézisével összhangban lévő magyarázatait tárgyalták, többek között azt, hogy a túl- és alulreagálás véletlenszerűen történik és egyformán gyakori (Fama, 1998). Továbbá annak lehetőségét is vizsgálták, hogy az intézményi befektetők (smart money) képesek ellensúlyozni a kevésbé tapasztalt befektetők (dumb money) által létrehozott anomáliákat (Shiller, 2003). Ugyanakkor kétséges maradt, hogy a befektetői racionalitáson alapuló modellek képesek-e befogadni a megfigyelt anomáliákat. Mindez az emberi pszichológiát is integráló modellek felé való elmozduláshoz és a viselkedési pénzügyek megjelenéséhez vezetett, amely megkérdőjelezi a befektetők tökéletes racionalitását az olyan viselkedési torzítások miatt, mint a veszteségkerülés, a túl- és alulreagálás. Az EMH és a viselkedési pénzügyek összehangolására tett egyik kísérlet az adaptív piacok hipotézisének (AMH) javaslata volt, amely elismeri és megmagyarázza a pénzügyi piacokon tapasztalható anomáliákat (Lo, 2004).

Mivel anomáliák létezhetnek, ezért nem meglepő, hogy a piaci szereplők nagy része a múltbeli árfolyamokra vonatkozó és a vállalat-specifikus információkat (múltbeli nyereség, veszteség és profitot), valamint egyéb tényezőket használ fel a jövőbeli részvényárfolyamok becsléséhez (Patel és Marwala, 2006). A tőzsdei előrejelzési tanulmányokban általában két jól ismert elemzési megközelítést, a fundamentális elemzést és a technikai elemzést alkalmaznak (Lohrmann és Luukka, 2019; Sedighi et al., 2019). A fundamentális elemzés az alapvető információkra összpontosít. Ha a fundamentumok alapján egy vállalat részvényárfolyamát vagy hozamát prognosztizálják, akkor olyan információk kapnak szerepet, mint például a vállalat bevételei és kiadásai, éves növekedési üteme, piaci pozíciója és a pénzügyi kimutatásokban vagy jelentésekben szereplő egyéb releváns tényezők. Egy részvényindex prognosztizálása esetén, amely számos vállalati részvényt képvisel, a piaci környezetre vonatkozó információk is bevethetők, beleértve a

nemzetgazdasági termelési adatokat, a kereskedelmet, az árfolyamokat vagy a kamatlábakat, amelyek valószínűleg hatással lesznek a részvényindexben szereplő vállalatok működésére. Ezzel szemben a technikai elemzés a részvényárfolyamok és a kapcsolódó kereskedési információk (mennység) múltbeli alakulásának tanulmányozását jelenti a részvényárfolyamok mozgásának előrejelzése érdekében (Wei et al., 2011). A témával kapcsolatos szakirodalom alapján megállapítható, hogy számos modell áll rendelkezésre az árfolyamok, hozamok és a volatilitás előrejelzésére, melyeket a kutatók három fő csoportba sorolnak. Az elsőbe a hagyományos statisztikai, a másodikba a valamilyen mesterséges intelligencia alapú, míg a harmadikban az úgynevezett hibrid módszerek tartoznak (Kim & Won, 2018; Vidal & Kristjanpoller, 2020; Zolfaghari & Gholami, 2021).

A mesterséges intelligencia (AI) és a gépi tanulás (ML) alkalmazása alapvetően alakítja át a pénzügyi szektort, amely közvetlenül vagy közvetve, de hatással van egyéb iparágakra is. A pénzügyi szolgáltatók jelentős befektetéseketallokálnak annak érdekében, hogy fejlesszék az adattudománnyal kapcsolatos területek kiépítését és fejlesztését. A 2007-2008-as pénzügyi válság óta különösen nagy figyelmet kap az adatvezérelt innováció és szabályozás, ami a banki és kereskedelmi gyakorlatok újraértékeléséhez vezetett. Az alternatív adatok, mint például hangfelvételek és közösségi médiabejegyzések, egyre nagyobb szerepet játszanak a döntéshozatalban, azonban az ilyen adatok elemzése kihívást jelent a hagyományos megközelítések számára, ezért kerültek előtérbe a gépi tanulási modellek. Ezek az algoritmusok biztosítják a szükséges számítási teljesítményt és rugalmasságot a komplex minták feltárásához. A közelmúlt fejlesztései lehetővé tették a tudományos elméletek hatékony alkalmazását a pontosabb előrejelzések készítése érdekében.

A legtöbb korábbi tanulmány a tőzsdei termékek előrejelzésére valamilyen statisztikai idősoros módszert alkalmazott, amely a múltbeli adatokra épített (Efendi et al., 2018). Ezek közül az autoregresszív feltételes heteroszkedaszticitás (ARCH), az autoregresszív mozgóátlag (ARMA) és az autoregresszív integrált mozgóátlag (ARIMA) modellek, a Kalman-szűrés és az exponenciális simítás a legnépszerűbb technikák (Chen & Chen, 2015; Yeh et al., 2011). Később, a mesterséges intelligencia (AI) és a soft computing megjelenésével ezek a technikák egyre nagyobb figyelmet kaptak a tőzsdei előrejelzéssel foglalkozó tanulmányokon esetében. A hagyományos idősoros módszerekkel ellentétben ezek a technikák képesek kezelni a tőzsde nemlineáris, kaotikus, zajos és összetett adatait, ami hatékonyabb előrejelzéseket eredményezhet (Chen & Hao, 2017). Ezek a módszerek innovatív és előnyös alternatívákat jelentenek, ami vonzóná teszi őket a kutatók számára a pénzügyi piacok előrejelzéséhez. A különféle módszertanok hiányosságai hívták életre a harmadik kategóriát, amelybe az úgynevezett hibrid prediktív modellek tartoznak. Ezek

kombinálják a hagyományos statisztikai és a gépi tanulás alapú módszereket a minél pontosabb becslési eredmény elérése érdekében (Reston et al., 2014; Büyüksahin és Ertekin, 2019).

Kutatásomban a legmodernebb előrejelző modelleket fogom megvizsgálni, amelyek a befektetői csoportok és vállalatok számára egyaránt fontos eszköznek számítanak a kockázatkezelés, a hozam- és a profitmaximalizálás területén. Az empirikus elemzésekhez a legnépszerűbb pénzügyi instrumentumokat, mint a részvényindexek (S&P500, DAX, Nikkei225), árupiaci termékek (nyersolaj, arany, ezüst), kriptovaluták (Bitcoin, Ethereum, Litecoin) és devizapárok (EUR/USD, GBP/USD, AUD/USD) adatait gyűjtöm össze a 2016. január 1. és 2022. június 30. időszakra vonatkozóan. A modellek robusztusságának tesztelése szempontjából fontos, hogy ebben a periódusban megtalálható a nyugalmi időszak (2018), a Covid19 (2020) és az orosz-ukrán konfliktus (2022) egyaránt. Mivel a kriptovaluták relatíve új terméknek számítanak a többihez képest, így az árfolyamadataik is kisebb időszakot ölelnek fel, így többek között ez indokolta az adatbázis kezdő és végpontjainak megválasztását. A modellezéshez három mély tanulási algoritmust (RNN, LSTM, GRU), továbbá az ezekből megalkotott három hibrid módszertant (LSTM-GRU, RNN-LSTM, RNN-GRU) vizsgálom regressziós elemzéssel. A valós és becsült árfolyamok közötti eltéréseket a MAPE mutató segítségével értékelem. Az eredmények ismertetését a terméktípusok szerinti vizsgálatokkal kezdem, majd ezt követi a termékenkénti és a modelltípusonkénti összehasonlítás. Az eredmények szakasz további részében pedig az egy- és többváltozós módszerek összevetésével, az abszolút legjobb és legrosszabb prediktív teljesítményekkel és az aktivációs függvény-optimalizálás hatásaival foglalkozom. A modellek előrejelzési eredményeit továbbá felhasználok egy kereskedési stratégia kialakításához, melyet a buy-and-hold módszerrel összehasonlítok. Így a dolgozat gyakorlati gazdasági hasznosulását is igyekszem majd hangsúlyozni számszerűsíthető befektetési eredményekkel.

2. SZISZTEMATIKUS SZAKIRODALMI ÁTTEKINTÉS

2.1. Bevezetés

A mesterséges intelligencia (AI) és a gépi tanulás (ML) alkalmazása a pénzügyi rendszerben teljesen átalakítja a szektort, amely hatással van más iparágakra és a társadalomra is egyaránt (Li és Tang, 2020). A hagyományos fedezeti alapoktól kezdve, a bankszektoron át, a pénzügyi technológiákkal foglalkozó (FinTech) szolgáltatókig bezárólag számos pénzügyi vállalkozás jelentős összegeket fektet be az adattudományi és a gépi tanulással kapcsolatos szakértelem megszerzésébe (Wall, 2018). A pénzügyi rendszerben a géppel olvasható adatok generálása, amelyet a számítási teljesítmény és a tárolás folyamatos növekedése támogat, jelentős hatással volt a pénzügyi ágazatra. Ezzel az adatközpontú megközelítéssel párhuzamosan folyamatosan szükség van a szabályozási rendszerek újragondolására, fejlesztésére. A 2007-2008-as globális pénzügyi válság nagymértékben hatással volt a pénzügyi ágazat regulációjának szerkezeti változásaira és ezzel előtérbe került az adatvezérelt innováció és szabályozás. Ez a banki hitelszerződések feltételeinek újraértékelését és elemzését, valamint a kereskedési könyv stressztesztelési programjait eredményezte Európában és az Egyesült Államokban (Goodell et al., 2021).

A pénzügyi szektorban dolgozó szakemberek egyre inkább érdeklődnek az alternatív adatok iránt, amelyek nem tartoznak bele a szokásos vállalati fundamentumok, értékpapírárak és makrogazdasági mutatók körébe. Ilyenek többek között a hangfelvételek, a hírek, a közösségi médiában közzétett bejegyzések és a műholdképek is. Ezek a széleskörű adatforrások azonban ma már jelentős befolyással bírnak a kereskedési döntések meghozatalára (In et al., 2019). Az adathalmazok tulajdonságait vizsgálta López de Prado (2019), aki megállapította, hogy a hagyományos megközelítések számára ezek a specifikumok meglehetősen nehezen értelmezhetők és elemezhetők, mivel gyakran nem számszerűsíthetők, strukturálatlanok, hiányosak és nem kategorizáltak. Ezért az ilyen adatok jellemzően magas dimenziójúak, azaz a változók száma gyakran elérheti vagy akár meg is haladhatja a megfigyelések számát (Duan et al., 2022). A fent említett anomáliák miatt, a lineáris modellezésre alapozott klasszikus ökonometria már kevésbé alkalmas az alternatív adatok felhasználásával történő előrejelző és determinisztikus modellek levezetéséhez. Ugyanis a nagy adathalmazokban rejlő, de gazdaságilag fontos információ észrevétlen marad (Goulet Coulombe et al., 2022). A gépi tanulási modellek biztosítják azt a számítási teljesítményt és funkcionális rugalmasságot, amely a nagydimenziós adatkörnyezetben lévő összetett minták feltérképezéséhez és megfejtéséhez szükséges. A közelmúltban a gépi tanulás területén elért fejlesztések lehetővé tették a tudományos elméletek alkalmazását a változók közötti kapcsolatok meghatározására a mélyebb feltárhatóság, a pontosabb előrejelzések és a szemléletesebb adatvizualizáció érdekében (Dixon et al., 2020). A klasszikus ökonometriai

modellek nem képesek átlátni és megtanulni a mögöttes kölcsönhatásokat, ami az eredmények nagymértékű torzításához vezet. A gépi tanulás, tehát megoldást nyújt ezen hiányosságok kiküszöbölésére, a kiugró értékek felismerésére, a jellemzők kinyerésére mindezt annak érdekében, hogy az összetett adatokon végrehajtható legyen az osztályozási vagy regressziós modell.

A mesterséges intelligenciában rejlő lehetőségek jelentős tudományos érdeklődést váltott ki különös tekintettel a gépi tanulás pénzügyi területen való alkalmazhatóságával kapcsolatban. Olyan fő területekre fókuszálnak, mint az árfolyamelőrejelzés (Nazareth és Reddy, 2023) pénzügyi modellezés (Chan és Hale, 2020), pénzügyi kockázatok megelőzése (Gao, 2022), az algoritmikus kereskedés (Gómez Martínez et al., 2019), az eszköz- és derivatíva árazás (Houlihan and Creamer, 2021), az automatizálás (Kokina et al., 2021), a csalásfelismerés (Teng és Lee, 2019), a hitel- és biztosítási kockázatvállalás (Bee et al., 2021), a kockázatkezelés (Li et al., 2021), hangulatelemzés (Chen et al., 2021). A fent említett főbb kategóriák közül az én szakirodalmi kutatásom elsősorban az árfolyamelőrejelző gépi tanulási modellekre helyezi a hangsúlyt, amely önmagában is egy meglehetősen szerteágazó és összetett területnek számít. Előtte azonban szeretnék egy átfogó képet adni a mesterséges intelligencia és a közgazdasági elméletek összefonódásával kapcsolatosan, amely segít jobban megérteni, hogy miért is van szükség innovatív eszközök alkalmazására a pénzügyekben.

2.2. A mesterséges intelligencia alkalmazhatósága a pénzügyekben

2.2.1. Pénzügyi piacok és hatékonyság

A hatékony piacok elmélete és annak kihívásai

A hatékony piacok elmélete (Efficient Market Hypothesis, EMH), amelyet Eugene Fama (1970) dolgozott ki, azt állítja, hogy a pénzügyi eszközök árai teljes mértékben tükrözik az összes elérhető információt. A piacokon keletkező új információk pedig azonnal beépülnek az árakba. Az elmélet három formáját különböztetik meg: gyenge, fél-erős és erős hatékonyság. A gyenge formájú piacokon a múltbeli árfolyamok nem nyújtanak előnyt a befektetőknek, a fél-erős hatékonyságú piacokon az összes nyilvánosan elérhető információ beépül az árakba, míg az erős hatékonyságú piacokon még a bennfentes információk sem biztosítanak kereskedési előnyt (Fama, 1991). A hatékony piacok hipotézisét részben a véletlen bolyongás elmélet (random walk theory) alapozta meg, mely több tudományos kutatás központi témája (Fama, 1965; Samuelson, 1965; Van Horne és Parker, 1967). Az elmélet szerint a piaci árfolyamok mozgása véletlenszerű, ezért az árakat nem lehet előrejelezni. Levy (1967) tanulmánya az elsők között volt, amely próbálta megcáfolni a random walk elméletet. Tudományos kutatásában arra a következtetésre jutott, hogy az

elektronikus számítógépek hatalmas adatfeldolgozási képességei felbecsülhetetlen értékűek a befektetési stratégiák kiválasztásában, továbbá segítenek a piaci időzítésen alapuló módszerek kidolgozásában és értékelésében is. Az empirikus eredmények alátámasztották, hogy a technikai elemző eszközöknek számos olyan előnyös tulajdonsága van, amely hasznosnak bizonyult a piaci árfolyammozgások előrejelzésében. A végső konklúzió pedig az, hogy a részvényárfolyamok jól felismerhető trendeket és mintákat követnek, amelyeknek fontos szerepe van az előrejelzések készítése során.

Az elmúlt évtizedek kutatásai és empirikus eredményei azonban egyre inkább azt mutatják, hogy a piacok nem mindig viselkednek teljes mértékben hatékonyan (Shiller, 2003). Az olyan piaci anomáliák, mint a momentumhatás (Jegadeesh és Titman, 1993) vagy az értékhatás (Fama és French, 1992) arra utalnak, hogy bizonyos befektetési stratégiákkal következetesen a piacinál jobb hozamot érhetünk el. A mesterséges intelligencia és a gépi tanulás alkalmazása a pénzügyi előrejelzésekben új dimenziót nyitott többek között hatékony piacok és a véletlen bolyongás elméletek megkérdőjelezésére. Az AI-alapú modellek ugyanis képesek olyan összetett mintázatok felismerésére, amelyek a hagyományos statisztikai modellekkel nehezen észlelhetők. Chopra és Sharma (2021) kutatásai szerint a mélytanulás képes a piaci hatékonyság korlátaiból adódó lehetőségek kiaknázására azáltal, hogy a nem-lineáris összefüggéseket sikeresen azonosítja a pénzügyi idősorokban.

Az adaptív piacok elmélete és a mesterséges intelligencia összefonódása

Lo (2004) adaptív piacok elmélete (Adaptive Market Hypothesis, AMH) egy alternatív megközelítést kínál a hatékony piacok hipotézisének megcáfolására. Az AMH arra épül, hogy a piacok nem teljesen hatékonyak, hanem dinamikusan változnak és alkalmazkodnak a megjelenő új információkhoz. A klasszikus közgazdaságtan racionális döntéshozónak tekinti a befektetőket, azonban a viselkedési közgazdaságtan kimutatta, hogy az emberi pszichológiai tényezők jelentős szerepet játszanak a pénzügyi döntésekben (Kahneman és Tversky, 1979). A befektetők gyakran a múltbéli tapasztalataik és a piaci környezet alakulásának függvényében módosítják döntéseiket, ami dinamikus és adaptív piacokat eredményez (Lo és Zhang, 2024). Az AMH képes megmagyarázni az olyan piaci anomáliákat, mint a momentum- és értékhatás, amelyeket az adaptív piacok elmélete szerint a befektetők alkalmazkodó viselkedése eredményez. Mindezt annak érdekében, hogy minél nyereségesebb stratégiákat alakítsanak ki. Az AMH elméletében a gépi tanulás kulcsszerepet játszhat, mivel képes alkalmazkodni a piaci változásokhoz és folyamatosan tanulni az újonnan keletkező információkból. Ez pedig jelentős előnyt biztosít a befektetők számára a minél magasabb profit elérése érdekében. Dixon és szerzőtársai (2020) tanulmányukban hangsúlyozzák, hogy a neurális hálózatok és más mesterséges intelligencia-alapú modellek az adaptív viselkedést támogatják a piaci előrejelzések során.

2.2.2. Alternatív adatok és információk hatékonyság

Aszimmetrikus információk és alternatív adatforrások szerepe

Az aszimmetrikus információk elmélete szerint (Akerlof, 1978; Stiglitz, 2000) a piaci szereplők nagyon eltérő mennyiségű információval rendelkeznek, ami torzítást okoz a döntéshozatali folyamatokban (Williams, 2005). A tradicionális pénzügyi elemzések leginkább a makrogazdasági mutatókra és a fundamentális adatokra támaszkodtak. Azonban az utóbbi évtizedek trendjei azt mutatják, hogy az alternatív adatok (közösségi média, műholdképek, keresési trendek) egyre nagyobb szerepet játszanak a piaci döntéshozatalban (In et al., 2019). A közösségi média adatai egyre fontosabb szerepet játszanak a pénzügyi döntéshozatalban. Ahern és Peress (2023) szerint a pénzügyi és a közösségi média kritikus szerepet játszanak az információ közvetítésében a piaci szereplők között, javítva a döntéshozatalt és növelve a piaci hatékonyságot. Sun et al. (2024) kutatásai szerint a közösségi média platformok jelentős hatással vannak a befektetői döntésekre, mivel gyors és széleskörű hozzáférést biztosítanak a pénzügyi információkhoz. Az alternatív adatok és a mesterséges intelligencia integrációja tehát forradalmasíthatja a pénzügyi döntéshozatalt. Az AI-alapú modellek képesek a nagy mennyiségű, összetett és strukturálatlan adat gyors és pontos elemzésére, melyből olyan információkat lehet kinyerni, ami a hagyományos modellek számára nem lenne hozzáférhető. Mindez lehetővé teszi a befektetők számára, hogy jobban megértsék a piaci dinamikát és előre jelezzék a jövőbeli árfolyammozgásokat.

Big Data és az információk hatékonyság kérdése

Shiller (2017) szerint a pénzügyi piacok hatékonysága nagymértékben attól függ, hogy a befektetők milyen típusú információkat vesznek figyelembe. A Big Data-alapú pénzügyi modellek lehetővé teszik, hogy a hagyományos fundamentális elemzéseken túl egyéb források is bevonhatóak legyen a döntéshozatali folyamatba. A Big Data, ahogy a neve is utal rá nagy mennyiségű és változatos adatok tárházát testesíti meg, amelyek feldolgozása és részletes elemzése a hagyományos módszertanokkal nem, vagy csak meglehetősen nehezen lenne kivitelezhető. Az ilyen adatok forrásai lehetnek például a tranzakciós vagy geolokációs adatok, közösségi média bejegyzések, webes adatgyűjtések és mobilalkalmazások különféle adatai (Hasan et al., 2020). Ezek az adatok megteremtik annak a lehetőségét a pénzügyi intézmények számára, hogy valós idejű, cselekvésre alkalmas betekintést nyerjenek a piaci trendekbe és a gazdasági teljesítménybe (Goldstein et al., 2024). Goulet Coulombe et al. (2022) vizsgálatai azt mutatják, hogy a hagyományos ökonometriai modellek gyakran nem képesek megfelelően kezelni ezeket a nagy dimenziós adathalmazokat, míg a gépi tanulási algoritmusok jobban alkalmazkodnak a

dinamikusan változó piaci körülményekhez. Ez új megközelítéseket tesz lehetővé az árfolyamok előrejelzésében és a piaci hatékonyság értékelésében.

2.2.3. Kockázatkezelés és pénzügyi stabilitás

Kockázatkezelési stratégiák

A kockázatkezelés az egyik olyan pénzügyi terület, amelyben a mesterséges intelligencia jelentős változásokat hozott. A hagyományos kockázatkezelési modellek statikus feltételezéseken alapulnak (VAR, cVAR) és nehezen tudják kezelni a pénzügyi piacok dinamikus és nem-lineáris természetét (Campbell és Koffi 2024). A mesterséges intelligencia lehetővé teszi a valós idejű kockázatkezelést, amely figyelembe veszi a piaci változásokat és a rejtett összefüggéseket. A mélytanulási algoritmusok képesek nagy mennyiségű piaci adat elemzésére, azonosítva a potenciális stresszhelyzeteket és piaci összeomlásokat (Peng és Yan 2021).

Rendszerszintű pénzügyi stabilitás és szabályozás

A pénzügyi stabilitás fenntartása érdekében a szabályozó hatóságok egyre nagyobb mértékben alkalmazzák az AI-alapú modelleket a rendszerkockázatok előrejelzésére és a pénzügyi krízisek megelőzésére. A 2008-as globális pénzügyi válság rávilágított arra, hogy a hagyományos makroprudenciális szabályozási eszközök nem mindig képesek időben jelezni a rendszerszintű kockázatokat (Danielsson, 2011). Az AI által támogatott makrogazdasági modellek viszont figyelembe tudják venni a komplex hálózati összefüggéseket, és így jobb előrejelzéseket nyújtanak a pénzügyi instabilitás potenciális forrásairól. A gépi tanulás továbbá képes a pénzmosás és egyéb pénzügyi bűncselekmények detektálására is (Agorbia-Atta és Atalor, 2024; Khan et al., 2024; Kute et al., 2021), amely segíti a szabályozó hatóságokat az átláthatóság növelésében. Emellett a stressztesztek és likviditási elemzések során az AI képes dinamikusan frissíteni az előrejelzéseket, lehetővé téve a központi bankok és egyéb pénzügyi intézmények számára, hogy proaktív lépéseket tegyenek a piaci stabilitás fenntartása érdekében (Araujo et al., 2023; Bodislav et al., 2024; Barongo és Mbelwa, 2024).

2.2.4. Portfóliókezelés és eszközallokáció

Modern portfólióelmélet, diverzifikáció és portfólió optimalizálás

A modern portfólióelmélet (Modern Portfolio Theory, MPT) Harry Markowitz (1952) munkáján alapul, amely szerint a befektetők optimalizálhatják portfóliójuk hozamát a kockázat minimalizálása mellett a diverzifikáció révén. Markowitz elmélete szerint a befektetőknek olyan portfóliókat kell kialakítaniuk, amelyek különböző eszközosztályokból állnak, hogy csökkentsék a kockázatot és növeljék a hozamot. A diverzifikáció alapelve szerint a különböző eszközök közötti

korreláció csökkenti a portfólió teljes kockázatát. A befektetők különböző eszközosztályokba, például részvényekbe, kötvényekbe és ingatlanokba fektethetnek, hogy csökkentsék a piaci volatilitás hatását (Micán et al., 2020). Ehhez nélkülözhetetlen a portfóliómonitoring, amely során a befektetők nyomon követik portfóliójuk teljesítményét és szükség esetén módosítják az eszközallokációt. A portfóliómonitoring célja a befektetési célok elérése és a kockázatok kezelése. A rendszeres portfólióértékelés és újraértékelés segít a befektetőknek az optimális portfólió fenntartásában és a piaci változásokhoz való alkalmazkodásban (Hoffmann, 2005).

Eszközallokáció

Az eszközallokáció a portfóliókezelés szintén egy nélkülözhetetlen eleme, amely meghatározza, hogy a befektetők milyen arányban osztják el tőkéjüket különböző eszközosztályok között. Sharpe (1992) szerint az eszközallokáció a portfólió teljesítményének legfontosabb meghatározója, mivel a megfelelő allokáció csökkenti a kockázatot és növeli a hozamot. A portfóliókonstrukció során a befektetők különböző eszközöket választanak ki és kombinálnak, hogy elérjék a kívánt kockázat-hozam profilt. A folyamat során figyelembe kell venni a befektetők kockázattűrő képességét, időhorizontját és pénzügyi céljait. A portfóliókonstrukciós modellek, például a Black-Litterman modell, segítenek a befektetőknek az optimális portfólió kialakításában a piaci várakozások és a kockázati preferenciák alapján (Satchell és Scowcroft, 2007; Cheung, 2010; Harris et al., 2017).

A mesterséges intelligencia szerepe a portfóliókezelésben és eszközallokációban

A mesterséges intelligencia megreformálja a portfóliókezelést és az eszközallokációt azáltal, hogy lehetővé teszi a hatalmas adatmennyiségek gyors és hatékony elemzését, valamint a dinamikus, adaptív stratégiák alkalmazását. Az AI segíthet az eszközallokációban azáltal, hogy valós időben képes modellezni a különböző eszközosztályok közötti korrelációkat, így javítva a diverzifikációt és csökkentve a portfólió kockázatát (Asawa, 2021; Pinelis és Ruppert, 2022; Ban et al., 2018). Ngo és szerzőtársai (2023) tanulmányukban a megerősítéses tanulás (RL) és a hagyományos portfólió optimalizáló technikák teljesítményét vetették össze és arra a következtetésre jutottak, hogy a gépi tanulás alapú módszer hatékonyabbnak bizonyult. Az AI-alapú portfóliókezelési rendszerek egyre inkább alkalmaznak természetes nyelvfeldolgozást (NLP) a pénzügyi hírek és közösségi média elemzésére, amely tovább javítja az előrejelzések pontosságát (Huang et al., 2024). Emellett az AI egyre nagyobb szerepet játszik a fenntartható és ESG (környezeti, társadalmi és irányítási) alapú befektetések kezelésében, mivel képes az alternatív adatforrások hatékony feldolgozására (Lim, 2024).

2.2.5. Eszközarázás

A tőkepiaci árfolyamok modellje (CAPM)

A tőkepiaci árfolyamok modellje (Capital Asset Pricing Model, CAPM) William Sharpe (1964) és John Lintner (1965) munkáján alapul, amely az eszközárak elméletének egyik alapköve. A CAPM szerint az eszközök várható hozama a kockázatmentes hozam és a piaci kockázati prémium függvénye. A modellt a viszonylag könnyen értelmezhető logikája miatt széles körben alkalmazzák a tőke költség becslésére és a portfóliók teljesítményének értékelésére (Elbannan, 2015; Mandala et al., 2023). Azonban a CAPM empirikus teljesítménye vegyes eredményeket mutat. Fama és French (2004) szerint a modell empirikus problémái részben a piaci portfólió helyettesítési problémáira vezethetők vissza. Ennek ellenére a CAPM továbbra is az eszközárak elméletének egyik legfontosabb modellje, amelyet széles körben tanítanak és alkalmaznak a pénzügyi gyakorlatban. Természetesen akadnak olyan tanulmányok is, amelyek a CAPM és a faktormodellek hatékonyságát is megkérdőjelezzik (Bartholdy és Peare, 2005).

Arbitrage Pricing Theory (APT)

Az Arbitrage Pricing Theory (APT), amely Stephen Ross (1976) munkáján alapul szintén alternatívát kínál a CAPM-hez képest. Az APT szerint ugyanis az eszközök várható hozama több makrogazdasági tényezőtől függ, amelyek különböző mértékben befolyásolják az eszközök árát. Az APT előnye, hogy rugalmasabb, mivel a CAPM-nél több tényezőt is figyelembe vesz az eszközárak alakulási folyamat során (Roll és Ross, 1980; Chen et al., 1986).

Derivatíva-árak és a Black-Scholes-Merton modell

A derivatívák árazása a modern pénzügyi piacok egyik központi problémája, amely hagyományosan a Black-Scholes-Merton modell (Black és Scholes, 1973; Merton, 1973) segítségével történt. Ez az egyenlet feltételezi, hogy a piaci hozamok normális eloszlást követnek és hogy az arbitrázsmentes feltételek fennállnak. Azonban a valós piaci adatok gyakran nem követik ezt a sémát, így a klasszikus modellek sokszor alulbecsülik a szélsőséges piaci események valószínűségét. A mesterséges intelligencia és a gépi tanulás képes pontosabban modellezni a piaci dinamikákat, figyelembe véve az időbeli nem-stacionaritást és az eloszlások vastag farkaiból adódó kockázatokat (De Spiegeleer, 2018). A mélytanulás (deep learning) segítségével a derivatíva-árak modellek képesek olyan rejtett mintázatok felfedezésére, amelyek javíthatják a volatilitás és az árfolyammozgások becslését. Ezen fejlesztések eredményeként a mesterséges intelligencia-alapú derivatíva-árak egyre inkább alternatívát kínál a klasszikus matematikai modellekkel szemben, lehetővé téve a piaci szereplők számára a pontosabb kockázati előrejelzéseket és árazási stratégiákat (Ivaşcu, 2021).

2.3. A szisztematikus szakirodalmi áttekintés módszertana

A szabványos módszertan alkalmazása a szisztematikus szakirodalmi áttekintés elvégzéséhez nemcsak a felülvizsgálat minőségét támogatja, hanem lehetővé teszi más kutatók számára a tanulmány megismétlését és összehasonlítását is. Ezt figyelembe véve disszertációmban a PRISMA (Preferred Reporting Items for Systematic Reviews and meta-Analyses) szabvány szerint végeztem el a téma irodalmának kutatását (Ardabili, 2022; Nazareth és Reddy, 2023).

A szisztematikus szakirodalmi adatbázis kialakításának legfontosabb irányelveit az alábbi kérdések alapján határoztam meg:

1. Melyik termékcsoporthoz a legnépszerűbb a prediktív modellezés szempontjából?
2. Melyek a leggyakrabban alkalmazott modellek?
3. Milyen teljesítményértékelési mérőszámokat alkalmaznak?
4. Milyen hosszúságú adatbázisokat használnak a kutatók?
5. Milyen statisztikai módszereket alkalmaznak?
6. Melyik modell tekinthető a legmegbízhatóbbnak és legpontosabbnak?

A kutatásom során a Google Scholar, a Science Direct és a Web of Science adatbázisait használtam. Utóbbi kettő a finomhangolás és a több paraméter alapján való leválogatás tekintetében sokkal jobban használható, mint a Google Scholar, amely ugyan a legkomplexebb keresőmotorral rendelkezik és így a legtöbb találatot is adja, de a releváns tanulmányok számának szűkítése szempontjából kevésbé hatékony.

A kulcsszavak meghatározásán és pontosítása nagy jelentőséggel bír a szisztematikus irodalmi áttekintésben. Végül arra a következtetésre jutottam, hogy a termékcsoporthozintű összehasonlítás miatt célszerű lenne ezt a megközelítést választani, így alakult ki az alábbi kereső kifejezés, amelyet mind a három adatbázis esetében alkalmaztam: "stock" OR "cryptocurrency" OR "commodity" OR "forex" AND "machine learning" AND "forecast".

Mindhárom alkalmazás esetében egységesen 10 évre (2014-2023) szűkítettem a keresést, valamint a további szűrési feltételeknél meghatároztam, hogy áttekintő és kutatási profilú publikációkat is megjelenítsen. Ezek alapján azonban még mindig rengeteg találatot kaptam, így további feltételként definiáltam, hogy a kulcsszavak a címben és az absztraktban szerepeljenek. A Google Scholar 1670, a Science Direct 750 és a Web of Science 371 publikációt adott eredményül. A keresés futtatásának időpontja: 2023.10.15. A szisztematikus irodalmi áttekintés további tanulmányokkal bővítettem ezt követően is, azonban ezek száma elenyésző, így külön ezeken nem emelem ki.

Az adatbázisban természetesen még nagyon sok átfedés volt, ezeket kiszűrve kialakult a nagyjából 683 cikkből álló mag, amelyeket cím és absztrakt alapján tovább szűkítve 267 publikáció maradt, további 157 cikket el kellett távolítani a folyóirat minősége (1. táblázat) miatt, illetve 10 szakirodalmi áttekintő tanulmány is kikerült az adatbázisból. Végül 100 tanulmány alkotta az adatbázist, amelyet feldolgoztam és elemeztem részletesen.


1. táblázat: A felvétel és kizárás minőségi kritériumai

Feltételek	Megtartás és kizárás oka
<i>Felvételi kritériumok</i>	
Megjelenés éve	A 2014-2023 között megjelent publikációkra koncentráltam.
Idegen nyelvű publikációk	A szisztematikus szakirodalmi áttekintőben feldolgozott összes cikk angol nyelven jelent meg.
Tematika	A gépi tanulási modellek előrejelzési teljesítményére fókuszáltam a pénzügyi és tőzsdei idősorok viszonylatában.
Tudományos publikációk	Ellenőrzött, releváns és minőségi ismeretanyagok a gépi tanulási modellekkel kapcsolatosan.
<i>Kizáró kritériumok</i>	
Más területekkel foglalkozó cikkek	A négy fő termékcsoporthoz kívüli idősorok (pl.: áramszükséglet, csapadék vagy tengerszint előrejelzés).
Konferenciakiadványok, könyvek, tanulmányok, műszaki jelentések, szakmailag lektorált diplomamunkák	A minőség és a következetesség biztosítása érdekében minden cikk

Forrás: saját szerkesztés

A szisztematikus irodalmi áttekintéssel az volt a célom, hogy megtaláljam azokat a publikációkat, amelyek a gépi tanulási modellek teljesítményét vizsgálják. Továbbá szerettem volna megtalálni azokat a kutatási hiányosságokat vagy új irányokat, amelyek az alapját képezhetik a disszertációm újdonságtartalmának. A téma szakirodalma igen gazdag. Rengeteg nagyon magas színvonalú publikáció található, amely kiválóan alkalmas arra, hogy a munkám elméleti háttérét megalapozza. Az összegyűjtött adatbázisból végül 4 különböző termékcsoporthoz bontva 100 cikket dolgoztam fel.

A jól definiált kulcsszavak és a kutatási kérdések segítségével sikerült azonosítanom és kizárnom azokat a publikációkat, amelyek nem kapcsolódnak szorosan a vizsgálatomhoz. Az alkalmazott módszertan szemléltetésére elkészítettem a saját szakirodalmi adatbázisom PRISMA-modelljét (1. ábra).




1. ábra: A keresés-értékelés szisztematikus grafikon

Forrás: saját szerkesztés Moher et al. (2009) alapján

Összességében elmondható, hogy a legtöbb releváns tanulmányt a Science Direct adatbázisából tudtam begyűjteni, míg legkevesebbet a Web of Science-ről, ugyanakkor ezek között nagy átfedés volt tapasztalható. A publikációs adatbázis feldolgozását a következő szakasz tartalmazza, amely után a 4 vizsgált termékcsoporthoz (részvénypiac, kriptovaluta, áruipiac és devizapiac) részletes bemutatása következik.

2.4. Szakirodalmi adatbázis elemzésének eredményei


Míg a korábbi időszakokban jellemzően inkább a hagyományos statisztikai módszertanok domináltak, addig az utóbbi 6-7 évben jelentősen megnőtt az érdeklődés (2. ábra) a mesterséges intelligencia így a gépi tanulási modellek, valamint az ilyen irányú kutatások iránt is (Henrique et al., 2019; Ghoddusi et al., 2019; Sezer et al., 2020; Ozbayoglu et al., 2020; Goodell et al., 2021; Rouf et al., 2021; Kumbure et al., 2022; Kumar et al., 2022; Ahmed et al., 2022). Az adatbázist tekintve különösen a 2020-2021-es évek voltak kiemelkedők, ami a megjelent publikációk számát illeti. Ez részben a Covid19 által okozott korlátozásoknak is köszönhető, mivel ebben az időszakban jóval produktívabbak voltak a kutatók.



2. ábra: Publikációk száma évenként (n=100)

Forrás: saját szerkesztés


Általánosságban megfigyelhető (3. ábra), hogy a gépi tanulási modellek előrejelző képességében rejlő potenciált leginkább a részvénytőzsiadon próbálják kiaknázni. Ugyanakkor jelentős gyarapodásnak indult a kriptovaluta piac is, ami a tudományos publikációk számát illeti. Nem elhanyagolható tovább az árupiaci szekció sem, amely nemcsak befektetési szempontból fontos, hanem a termelő vállalatok optimális nyers- és alapanyag igényének meghatározása miatt is. Az általam vizsgált termékkategóriák közül a legcsekélyebb mennyiségű tanulmány a deviza piacot vizsgálja. Ez részben azzal is magyarázható, hogy a két vezető kategória instrumentumai jelentős volatilitással bírnak, amelyek esetében a mesterséges intelligencia módszertanok kiemelkedő nemlineáris és a szélsőséges mozgásokat felismerő képessége komoly előnyt biztosít a hagyományos statisztikai modellekkel szemben.



3. ábra: Publikációk megoszlása termékkategóriák szerint (n=100)

Forrás: saját szerkesztés


A publikációk termékkategória és időbeli megoszlása alapján (4. ábra) megállapítható, hogy a 2019-es évig a részvénytőzok domináltak, majd a Covid19 időszakában (2020-2021) ezt a szerepet átvették a kriptovaluták. Ennek gyakorlati okai is lehetnek, mégpedig, hogy ezek a termékek decentralizáltak és kevésbé függenek a gazdasági fundamentumoktól, így a válságos időszakokban felértékelődik a jelentőségük. Hasonlóan érdekes megfigyelést tehetünk, ha az árupiacot vizsgáljuk az orosz-ukrán háború kirobbanásának évében, 2022-ben. Ugyanis ekkor a figyelem a tudományos kutatások tekintetében is ebbe az irányba tolódott el. Fontos megemlíteni, hogy elsősorban az energiahordozók (olaj, gáz) kerültek előtérbe, mind elméleti mind gyakorlati szinten. A 2023-as évben úgy tűnik, hogy megint a részvénytőzok felé fordultak a kutatók.



4. ábra: Publikációk megoszlása idő és a termékkategóriák szerint

Forrás: saját szerkesztés

A következők statisztikák már első sorban a kutatási területen alkalmazott módszerekre fókuszálnak. A 5. ábrán jól látszik, hogy az általam feldolgozott tanulmányok közül kiemelkedően a legtöbbször az LSTM modellt alkalmazták. A második és harmadik helyen jelentős lemaradással az SVR és az RF áll, majd egy hagyományos statisztikai eszköz következik az ARIMA. A publikációkban előszeretettel hangsúlyozzák, hogy mennyivel előnyösebb tulajdonságokkal rendelkeznek a gépi modellek az autoregresszív módszerekkel szemben. Összességében elmondható az is, hogy a neurális hálózatok és ezek különféle altípusai dominálják a publikációkat.




5. ábra: Top 10 alkalmazott módszertan (n=100)

Az adatok 100 publikációra vetítve vannak, de egy módszertan több cikkben is megjelenhet.

Forrás: saját szerkesztés

Rendkívül fontos szempont, hogy milyen mutatók alapján lehet összehasonlítani az egyes modellek teljesítményét. Az 5 leggyakrabban alkalmazott teljesítményértékelési mérőszámot a 6. ábra mutatja be. A legtöbb esetben az RMSE mutatóval találkoztam a publikációkban. Nyilván ezeknek a mutatószámoknak is megvan az előnye és hátránya. Ha azonos termékcsoportok előrejelezhetőségét vizsgáljuk, akkor sokkal szélesebb körben válogathatunk, azonban, ha több különböző típusú adatot szeretnénk összevetni, akkor szükségünk van egy skálafüggetlen értékelési módszerre. Ez pedig nem más, mint a MAPE, amely jelen esetben a harmadik legtöbbet alkalmazott mutató. Túlnyomó többségében valamilyen regressziós modell szerepelt a tanulmányokban ezért láthatjuk az első 4 helyen az ilyen típusú értékelési mutatókat. A top 5-be egy klasszifikációs módszer is szerepelt az ún. Accuracy.




6. ábra: Top 5 teljesítményértékelési mérőszám (n=100)

Az adatok 100 publikációra vetítve vannak, de egy módszertan több cikkben is megjelenhet.

Forrás: saját szerkesztés


A 7. ábra azt mutatja, hogy a szisztematikus irodalmi áttekintésbe bevont publikációk milyen terjedelmű adatbázisokat elemeztek. Látható, hogy leggyakrabban az 1 és 10 év közötti intervallumot preferálják, míg a második legtöbbet alkalmazott adatbázis hossz a 11-20 év. A feldolgozott cikkek között volt kettő, amely kiemelkedően hosszú periódust elemez (47 évnyi adat). Ezek mindegyike a deviza piacot vizsgálta.



7. ábra: Publikációk megoszlása az adatbázisok hossza alapján (n=100)

Forrás: saját szerkesztés

A statisztikai módszertan tekintetében (8. ábra) a valamilyen regressziós modellt alkalmazó tanulmányok száma kiemelkedő, melyet a klasszifikáció követett. Néhány publikációban előfordult, hogy két módszert is használtak. A kutatásom szempontjából azonban a regresszióval foglalkozó cikkek a legrelevánsabbak.




8. ábra: Publikációk megoszlása statisztikai módszerek szerint (n=100)

Forrás: saját szerkesztés

Amit még fontosnak tartottam bemutatni a publikációs adatbázis statisztikái közül, hogy mely folyóiratokhoz köthetőek ezek a tanulmányok. Az általam vizsgált tanulmányok közül negyede az Expert Systems with Applications-ben és az Applied Soft Computing-ban jelent meg (9. ábra). Ez

kifejezetten előnyösnek tekinthető abból a szempontból, hogy sokkal részletesebben tárgyalják a modellekkel kapcsolatos specifikációkat, ezáltal még inkább el tudtam mélyülni a gépi tanulás rejtelmeiben.



9. ábra: Megjelent publikációk száma folyóiratok szerint (top 15)

Forrás: saját szerkesztés

2.5. A vizsgált piacok szakirodalmának ismertetése

2.5.1. Részvénytőrségi előrejelzések

A mesterséges intelligencia alapú modelleknek számos előnye van a hagyományos statisztikai modellekkel szemben, mivel komplexitásukból fakadóan az előrejelző képességük jóval pontosabb. A tanulási képességük miatt képesek felismerni az adatokban jelenlévő mintázatokat, így a nemlineáris mozgásokat. A részvényadatok nem állandó (non-stationary) és nemlineáris mozgásokat mutatnak, amelyeket a hagyományos statisztikai modellek nem vagy csak nehezen képesek detektálni, ezért az AI alapú módszertanok egy idő után átvették a vezető szerepet ezen a területen. 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 (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 mesterséges neurális hálózatokkal szemben. Ezen módszerek közül is kiemelkedik a hosszú-rövid távú memória (LSTM) modell, amelyet a

szekvenciális adathalmazok tekintetében széles körében alkalmaznak. A modellváltozat előnyös tulajdonsága, hogy nagyfokú alkalmazkodóképességet mutat az idősorok elemzésében.

Nabipour és kutatócsoportja (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 anyag és fémalapanyagokkal foglalkozó vállalatok részvényadatain. Arra a következtetésre jutottak, hogy az RNN és az LSTM minden egyéb prediktív modell teljesítményét felülmúlta.

Hiransha és szerzőtársai (2018) az indiai tőzsde (NSE) és a NYSE részvényeinek árfolyamalakulásával 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. Az ARIMA módszer outputjaival is összevetették az eredményeket és ebben az összehasonlításban is a CNN volt az optimális választás. Beniwal és szerzőtársai (2023) a Nifty50, a DJIA, a DAX, a Nikkei225 és az SSE indexek adatait vizsgálták 2013. január és 2022. december között SVR, LSTM, valamint egy OGA-SVR (Optimized Genetic Algorithm-based Support Vector Regression) modell segítségével. Megállapították, hogy a hibrid módszer a leghatékonyabb az általuk elemzett részvényindexek előrejelzésére. Velük ellentétben a következő két tanulmány az LSTM modell erőseit hangsúlyozza. Rather (2021), aki szintén az indiai értéktőzsde NIFTY-50 index részvényeinek árfolyamelőrejelzésével foglalkozott a 2018. január és 2021. április közötti időszakra vonatkozóan. Arra a következtetésre jutott, hogy az általa javasolt LSTM-DNN (Long short-term memory – Deep Neural Network) modell kiemelkedően jól teljesített az MLP (Multilayer Perceptron) és az ARIMA módszertanokhoz képest. Banik és társai (2022) is hasonló következtetésre jutottak az indiai tőzsde részvényeinek elemzése során. Ők az LSTM modellt technikai indikátorokkal kombinálták. Az így kialakított módszer a többinél hatékonyabbnak bizonyult.

A feldolgozott publikációk alapján a részvénytőzsi piacokra vonatkozóan megállapítható (10. ábra), hogy a leggyakrabban az S&P500 indexet használják az előrejelző modellek bemeneti adatbázisaként. Ennek legfőbb oka, hogy az egyik legismertebb benchmark index, illetve egy jól diverzifikált portfólió, amely relatíve kiegyensúlyozott teljesítményt mutat.



10. ábra: Top 5 részvényindex (n=33)


Az adatok 33 publikációra vetítve vannak, de egy index több tanulmányban is megjelenhet

Forrás: saját szerkesztés

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 algoritmus produkálta a legjobb eredményt. Siami-Namini és kutatótársai (2018) a Nikkei 225, az S&P 500, a NASDAQ composít, a Hang Seng és a Dow Jones részvényindexeket vizsgálták a 1985-2018 közötti időszakban. Az ARIMA és az LSTM módszerek teljesítményét hasonlították össze egymással és azt találták, hogy az LSTM jobb becslési pontosságot ért el, mint az ARIMA. 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 teljesítményt illeti, azonban van egy komolyabb hiányossága is mégpedig, hogy nem tudja megjeleníteni az idősorok többfrekvenciás jellemzőit, ezért az adatok frekvenciatartományának modellezését nem teszi lehetővé. Bhandari és munkatársai (2022) a 2006 és 2020 közötti időszakban vizsgálták az S&P500 index árfolyamalakulását egy- és többrétegű LSTM modellekkel. A kísérlet talán meglepő eredménnyel szolgált, ugyanis megállapították, hogy az egyrétegű LSTM modell jobb illeszkedést és magasabb előrejelzési pontosságot biztosít a többrétegű LSTM modellekhez képest. Ezzel cáfolták azt a teóriát, hogy a több rejtett hálózati réteg alkalmazása növelheti a prediktív teljesítményt. Liang és munkatársai (2019) a hagyományos LSTM és a wavelet-transzformációval kiegészített LSTM modell prediktív teljesítményét vizsgálták az S&P500 index adatain. Munkájukkal azt bizonyították, hogy a WT-LSTM felül tudja

teljesíteni a hagyományos hosszú-rövid távú memória metódust. Qiu és szerzőtársai (2020) által végzett kutatás is a fenti eredményeket támasztják alá. Ők az S&P500, a DJIA és a HSI adatain is tesztelték az általános és a wavelet transzformációval bővített LSTM, illetve GRU modelleket. Mindegyik adathalmaz esetében igazolódott, hogy az általuk javasolt WT-LSTM módszer teljesített a legjobban. Skehin és kutatótársai (2018) a NASDAQ-en jegyzett FAANG (Facebook, Apple, Amazon, Netflix, Google) részvények vizsgálatánál azonban arra a következtetésre jutottak, hogy az Apple kivételével minden egyéb esetben az ARIMA felülteljesítette az WT-LSTM-et. 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. Ezt hibrid és hagyományos módszerekkel hasonlították össze. Az adatkészletük az S&P500 és HSI indexek adatait tartalmazta. 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. Hajiabotorabi és szerzőtársai (2019) az S&P500, a NASDAQ composite, a DJIA és az NYSE indexek alakulását vizsgálták a 2000. június és 2009. június közötti időszakban, melyhez a hagyományos ARIMA és GARCH modelleken kívül hibrid típusokat is alkalmaztak (BSd-RNN, DWT-RNN, DWT-FFNN). Ebben a tanulmányban a BSd (B-spline d) többszörös felbontást választották előfeldolgozó eszközként az RNN modell javítására. A gyakorlati eredmények alapján a javasolt BSd-RNN modell hatékonyabbnak bizonyult a nemlineáris idősorok, például a volatilitási idősorok előrejelzésében. Gülmez (2023) a DJIA index részvényeit elemezte a 2018. január és 2023. január közötti időszakban az LSTM, az ANN, valamint két hibrid LSTM modell alkalmazásával. Az eredmények egyértelműen azt mutatták, hogy az LSTM-ARO (Artificial Rabbits Optimization) a legjobb a modellek közül.

A szakirodalmi gyűjtés alapján megállapítható, hogy a leggyakrabban használt adatbázishossz (11. ábra) az 1-10 évig terjedő intervallum. Számottevő még a 11-20 év közötti kategóriába tartozó idősor méret, míg az ettől hosszabbak már elenyésző mennyiséget képeznek.




11. ábra: Publikációk megoszlása az adatbázisok hossza alapján a részvényt piacok esetében (év) (n=33)

Forrás: saját szerkesztés

Zhang és kutatócsoportja (2017) 50 különböző részvény árfolyamváltozását vizsgálta a 2007 és 2016 közötti időszakban az AR, az LSTM és az SFM (State Frequency Memory) modellek felhasználásával. Azt a megállapítást tették, hogy az SFM modell felülteljesítette az AR és az LSTM előrejelző képességét, köszönhetően a kiemelkedő multifrekvenciás mintafelismerésének. Hanauer és szerzőtársai (2023) 32 különböző ország részvényeit használták az elemzésükhöz, mely az 1990. július és 2021. december közötti időszakot fedte le. Módszerek tekintetében a LR, elasztikus háló, RF, GBRT (Gradient Boost Regression Tree) és az ANN típusokat hasonlították össze egymással. Megfigyelhető volt, hogy a fa alapú módszerek és neurális hálózatok jobban képesek azonosítani a nemlinearitás kapcsolatokat és azok kölcsönhatásait. Ezenkívül a gépi tanulási modelleken alapuló hozam előrejelzések a hagyományos lineáris modellekhez képest jobbnak bizonyultak.

Nelson és kutatótársai (2017) a Brazil tőzsde részvényadatain a többrétegű percepciós, a Random Forest, valamint az LSTM modelleket alkalmazták és arra a kérdésre keresték a választ, hogy a három közül melyik képes a legpontosabb előrejelzésre. Azt találták, hogy a pontosság tekintetében az LSTM volt a legmegfelelőbb. Kristjanpoller és munkatársai (2014) ANN-GARCH kombinált modellt alkalmaztak latin-amerikai (Brazília, Chile, Mexikó) tőzsdeindexek előrejelzésére. Az eredményeik azt mutatták, hogy az ANN javítani tudja a GARCH (1, 1) prediktív teljesítményét.

A részvénytársadatokkal kapcsolatos szakirodalom vizsgálata során (12. ábra) az alkalmazott módszertanok tekintetében az LSTM sokszor kap szerepet a prediktív modellezésben. Ez a népszerűség a kiemelkedő előrejelzési teljesítményével magyarázható.



12. ábra: Top 10 alkalmazott módszertan a részvénytársadatok esetében


Forrás: saját szerkesztés

Nikou és munkatársai (2019) az iShares MSCI UK tőzsdén kereskedett részvényalap 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. Ayala et al. (2021) az IBEX, a DAX és az DJIA indexek alakulását tanulmányozták a 2011. január és 2019. december közötti időszakban, melyhez az LR, RF, ANN, és SVR módszertanokat használták fel. Megállapították, hogy az ANN teljesítménye kiemelkedőnek számít. Az elért eredmények továbbá azt mutatták, hogy a gépi tanulási modellek kombinálása a technikai elemzési stratégiákkal képesek javítani a kereskedési jelzések felismerését és az alkalmazott szabályok versenyképességét. Ballings és kutatótársai (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. Ebben az esetben a végeredmény azt mutatta, hogy a Random Forest volt az, amely a legjobb teljesítményt produkálta túlteljesítve a neurális hálós modelleket. Basak és szerzőtársai (2019) az XGBoost, a logisztikus regresszió, a SVM, az ANN és a Random Forest módszereket alkalmazták a részvénytársadati trendek előrejelzésére (Apple, Amazon, Microsoft, Facebook, Twitter, Nike, Tata, Osram). Az eredmények

ennél a tanulmánynál is azt támasztották alá, hogy a Random Forest teljesítménye kiemelkedett a többi közül.

Chong és munkatársai (2017) a Koreai Értéktőzsde 38 legnagyobb piaci kapitalizációval rendelkező részvény 2010. január és 2014. december közötti adatait használták fel kutatásukhoz. A kutatási eredmények szerint a DNN modell képes felülmúlni az AR és az ANN teljesítményét. Azt is megállapították, hogy a prediktív teljesítmény tovább javítható az AR-DNN hibrid módszer kialakításával. Md et al. (2023) a Samsung részvény előrejelzésére tettek kísérletet a 2016-2021 közötti időszakra vonatkozóan. Az általuk alkalmazott modellek közül (LR, SVR, LSTM, RNN, CNN, MLP) az LSTM túlteljesítette az összes többit. Azt a következtetést is levonták, hogy az LSTM hajlamos a túlillesztésre, ezért a modell optimalizálásnál erre különösen figyelni kell.

A szakirodalmi adatbázis alapján kiderült, hogy a modellek értékelésére leggyakrabban használt teljesítményértékelési mutató az RMSE (13. ábra), melyet a MAPE követ. Előbbivel csak termékkategóriákon belüli modellösszehasonlítás végezhető, míg utóbbival több különböző termék előrejelezhetőségének pontossága is összevethető.



13. ábra: Top 5 teljesítményértékelési mérőszám a részvénytőzsdák esetében

Forrás: saját szerkesztés

Liu szerzőtársaival (2021) az SSE 50 részvényindex adatait vizsgálta a 2017. május és 2019. júliusi időszakra vonatkozóan, melyhez az RNN, GRU, LSTM módszereket használták fel. Az eredmények alapján az LSTM modell jobb teljesítményre volt képes, mint a GRU és a legegyszerűbb modell az RNN bizonyult a legkevésbé hatékornak. Long és munkatársai (2020) gépi tanulási (Random Forest, Adaptive Boosting), kétirányú mély tanulási (BiLSTM) és egyéb neurális hálós modelleket alkalmaztak, hogy megvizsgálják kínai részvényárfolyamok trendjeinek

előrejelezhetőségét. A leghatékonyabb teljesítményre a BiLSTM volt képes, messze felülmúlva a többi előrejelzési módszert.

Jiang et al. (2023) a CSI100, CSI200, CSI500, GEI100, NASDAQ100 és az NYSE100 részvényindexek adatain kísérleteztek 2015. január és 2022. december közti időszakra vonatkozóan. Vizsgálatuk meglehetősen alapos volt, mert nagyon sokféle módszert alkalmaztak (AR, logisztikus regresszió, ARIMA, GARCH, LightGBM, CNN, RNN, LSTM, TCN, ALSTM, SFM, ADA-RNN, CATN, HMM-ALSTM, MLP). A kutatók által javasolt HMM-ALSTM valamennyi vizsgált index esetében a legjobb előrejelző teljesítményre volt képes a hozamvárakozások, valamint a piac irányának meghatározása tekintetében. Yao és kutatótársai (2023) 2010. január és 2022. augusztus közötti időhorizonton elemezték az SSE, DJIA, FTSE100, CAC40, Nikkei225, RTSI (Russian Trading System Index) és STI (Straits Times Index - Singapore) indexek alakulását. Az eredmények alapján azt találták, hogy a különböző dekompozíciós algoritmusok TCN-moddal való kombinációja után az előrejelzési teljesítmény jelentősen javult. Megállapították továbbá, hogy a MEMD-TCN modell előrejelzési eredményei szignifikánsan jobbak a többi modellhez viszonyítva (ARIMA, RF, SVR, GRU, TCN, WT-GRU, WT-TCN, EMD-GRU, EMD-TCN, EEMD-GRU, EEMD-TCN, CEEMDAN-GRU, CEEMDAN-TCN, MEMD-GRU). Behera et al. (2023) a következő módszereket használták fel a BSE, a Tokyo SE és az SSE indexek részvényadatainak vizsgálatához: RF, XGBoost, AdaBoost, SVR, KNN, ANN, MVaR (Mean Value at Risk). A kísérleti eredmény azt mutatta, hogy az AdaBoost modell az MVaR-al kombinálva teljesített a legjobban többihez képest. Yu és kutatócsapata (2023) különféle neurális hálózati modellekkel vizsgálták az SSE, S&P500 és az FTSE indexeket a 2000. január és 2022. június közötti időszakban. A tanulmányban javasolt hibrid modell (GVMD-Q-DBN-LSTM-GRU) teljesítménye pontosabb eredményeket tud nyújtani az 1, 5 és 22 lépéses előrejelzésben. Érdemes megjegyezni, hogy tanulmány fontos elméleti értékkel és gyakorlati jelentőséggel bír a befektetők számára, hogy időben kiigazítsák a kereskedési döntéseiket és elkerüljék a kockázatokat a nyereség maximalizálása érdekében. A szabályozó hatóságok számára szintén hasznos eszköz, hogy felfedezzék a rendellenes tendenciákat és biztosíthassák a pénzügyi piacok stabil, gyors fejlődését. Jing és munkatársai (2021) a Shanghai-i 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 alkalmaznánk az előrejelzésekhez. Alzaman (2023) a TSE (Toronto Stock Exchange) részvényeit használta bemeneti adatként az LSTM és a GA algoritmusok futtatásához. Azt tapasztalta, hogy a hiperparaméter-optimalizálás jelentősen javítja a modellek teljesítményét. A GA módszertan esetében az előrejelzési teljesítmény közel 40%-kal javult az elvégzett optimalizáció hatására.

Az előzőek alapján megállapítható, hogy a részvénypiaci gépi tanulási előrejelzések kapcsán a szakirodalom dominánsan az LSTM, GRU, XGBoost, valamint Random Forest és CNN modellek alkalmazását dokumentálja. A tanulmányok többsége ugyan jelentős predikciós pontosságot mutat – jellemzően RMSE, MAE vagy MAPE mutatókkal igazolva – azonban ezek az eredmények sokszor rövid időtávon (1-2 év) értelmezhetők, így az időbeli általánosíthatóságuk erősen korlátozott. Számos modell nem veszi figyelembe a különböző piaci rezsimek hatását vagy azt, hogy ugyanazon modell teljesítménye miként változik extrém volatilitás vagy gazdasági válságok esetén. További problémát jelent, hogy a bemeneti változók sok esetben csak árfolyam- vagy technikai indikátor alapúak, miközben a piaci hangulat, volumen, híráramlás vagy makrogazdasági változók (pl. GDP-növekedés, infláció, kamatlábak) ritkán kerülnek bevonásra. Így a modellek előrejelző képessége sokszor a piaci kontextus figyelmen kívül hagyásával történik. A módszertanok gyakran nem transzparensak: kevés információ áll rendelkezésre a hiperparaméterek kiválasztásáról, validációs stratégiáról vagy a túlillesztés megelőzéséről. Az is ritka, hogy az előrejelzési eredményeket konkrét kereskedési stratégiákkal teszteljék (pl. backtesting, drawdown-analízis), holott ezek nélkül a prediktív érték nehezen ültethető át valós piaci döntésekre. Összességében tehát a részvénypiaci irodalom technológiailag fejlett, de gyakran hiányzik belőle a gazdasági-kereskedési kontextusba ágyazottság, ami akadályozza a modellek gyakorlati adaptációját.


2.5.2. Árupiaci előrejelzések

Liang és kutatótársai (2022) szintén az arany árfolyamalakulását elemezték 22 különböző gépi tanulási modell segítségével. A gyakorlati eredmények azt mutatják, hogy a továbbfejlesztett ICEEMDAN-LSTM-CNN-CBAM jobb előrejelzéssel rendelkezik, mint a többi 21 modell. A CNN és LSTM modellek kombinálásának előnyeit hangsúlyozza az arany esetében Livieris kutatótársai (2020), akik négy különféle módszert használtak (SVR, FFNN, LSTM, CNN-LSTM). Az általuk javasolt algoritmust (CNN-LSTM) a legkorszerűbb mélytanulási és gépi tanulási modellekkel szemben értékelték. Az kísérleti elemzés azt mutatta, hogy az LSTM rétegek konvolúciós rétegekkel együtt való alkalmazása jelentős javulást eredményez az előrejelzési teljesítményben.

Ozdemir és kutatótársai (2022) a nikkelt, alumíniumot, rézt, aranyt, vasat, ólomot, ezüstöt és cinket közép és hosszú távú árfolyamelőrejelzésével foglalkozik tanulmányában. Két fejlett mélytanulási architektúrát alkalmaznak, nevezetesen az LSTM-et és a GRU-t. Az előrejelzési teljesítmény értékelésére a MAPE kritériumot alkalmazzák. Mindkét modell esetén igazolták azok előrejelzésre való alkalmasságát. Az előrejelzési képesség mellett tesztelik a számítások gyorsaságát, mivel a nagyfelbontású adatok feldolgozásakor a sebesség fontos tényező lehet. A tanulmányban

megállapítást nyert, hogy a GRU-hálózatok 33%-kal gyorsabbak voltak, mint a LSTM-hálózatok. Shi és szerzőtársai (2023) kombinálták a fent említett két módszert az alumínium, alumíniumötvözet, réz, ólom, ón, arany, palládium, platina és ezüst elemzésével kapcsolatos tanulmányukban. A Covid19 hatását is figyelembe véve a különböző fém ásványi anyagok azonnali árának előrejelzett eredményei azt mutatták, hogy az LSTM hibrid modellek nagy előrejelzési pontossággal rendelkeznek, melyek közül az LSTM-GRU bizonyult a legjobbnak. Zhang és munkatársai (2021) a réz árfolyamának előrejelezhetőségét modellezték MLP, SVR, RF, KNN és Gradient Boost módszertanok segítségével. A különböző gépi tanulási technikák átfogó összehasonlítása azt mutatja, hogy az MLP neurális hálózat (mély tanulási technikákkal) a legjobb módszer a réz havi árfolyamának előrejelzésére.

Az általam vizsgált publikációkban az árupiaci elemzéseket (14. ábra) tekintve messze a Crude olaj a leggyakrabban használt instrumentum. Népszerű továbbá az arany és az ezüst is. Az agrárpiaci termékek közül pedig a szójabab, ami még befért a top 5-be. A szakirodalom alapján az árupiaci produktumok előrejelezhetősége tekinthető a legváltozatosabbnak a 4 kategória közül, mert itt a legszélesebb a termékpaletta, melyek egyedi tulajdonságai igazi kihívást jelentenek a kutatók és modellezők számára.



14. ábra: Top 5 árupiaci termék (n=24)

Az adatok 24 publikációra vetítve vannak, de egy árupiaci termék több cikkben is megjelenhet.


Forrás: saját szerkesztés

A mezőgazdasági áruk területén is népszerű témának számít a gépi tanulás alapján történő árfolyamelőrejelzés. Fang és szerzőtársai (2020) a növényi liszt, szójaliszt, szárított rizs, kemény búza, Zheng gyapot és korai Indica rizs árának alakulását elemezték ARIMA, ANN és SVR módszertanok segítségével. Azt találták, hogy a két nemlineáris modell teljesítménye jobb, mint a

lineáris ARIMA-é, azonban a két nemlineáris modell között nincs nyilvánvaló különbség. Az eredmények különösen a nagyfrekvenciás komponensek előrejelzésében mutatnak nagyobb pontosságot az SVM és az ANN használatával. Ribeiro és kutatótársai (2020) a szójabab és a búza idősorain alkalmazták a Gradient Boost, XGBoost, RF, SVR, KNN, MLP, KNN-XGB-SVR előrejelző modelleket. Az eredmények lehetővé tették annak igazolását, hogy a mezőgazdasági nyersanyagok rövid távú előrejelzésében a hibrid módszer (KNN-XGB-SVR) jobban teljesít, mint az önálló modellek. Ez a kombinált megközelítés kis előrejelzési hibákkal és nagy pontossággal működött. Liu et. al. (2022) kutatásukban a szójabab árfolyamára fókuszált és szintén a hibrid megközelítést részesítették előnyben. Módszertanok széles tárházát alkalmazták (CNN, GRU, CNN-GRU, LSTM, MLP, SVR, CEEMDAN-CNN, CEEMDAN-CNN-GRU, CEEMDAN-GRU, CEEMDAN-LSTM, CEEMDAN-MLP, CEEMDAN-SVR). A kutatás megerősíti, hogy a fuzzy entrópia K-közép klaszterezés a figyelem alapú neurális hálózattal (CNN-GRU-Attention) és a CEEMDAN megközelítés alkalmazásával párosulva minden modellnél jobban teljesít, így pontosabban képes megjósolni a szójabab azonnali árát. Továbbá azt is megállapították, hogy számos tényező, mint például az éghajlatváltozással, a természeti katasztrófákkal, a nemzetközi kereskedelemmel és a makrogazdasági politikával kapcsolatos bizonytalanságok szintén hatással vannak a szójabab azonnali árfolyamára. RL és munkatársai (2021) a gyapotmag, mustármag, szója vetőmag, ricinus mag, guar mag árfolyamait elemezték ARIMA, LSTM és TDNN (Time-delay Neural Network) módszertanokkal. Az LSTM minden esetben a legjobb előrejelzési pontosságot nyújtotta összehasonlítva a TDNN és az ARIMA modellekkel. Továbbá mind a TDNN, mind az LSTM lényegesen jobban teljesített az idősorok irányváltásának előrejelzésében a lineáris modellnél. Ezek az irányok különösen fontosak a piaci hangulat és az üzleti ciklusok meghatározásában. Deepa et al. (2021) a gyapot árfolyam alakulását vizsgálta 4 különféle módszerrel (LR, BLR, Gradient Boost és RF). A kísérleti eredmények azt bizonyítják, hogy a Gradient Boost algoritmus jobb eredményeket produkál, mint a többi vizsgálati módszer. Emellett a lineáris regressziós modell és a bayesi regressziós modellek is jól működött, azonban az RF erre az adatkészletre nem adott jó eredményeket. Ouyang és szerzőtársai (2019) tanulmányukban idősor elemzést végeztek a gyapot, cukor, bab, szójabab olaj, kardamom, kemény búza, kukorica, kávé, kakaó és narancslé koncentrátum termékeken, melyhez az LSTM, CNN, RNN, ARIMA és VAR modelleket használták. Az empirikus kutatás azt mutatja, hogy a konvolúciós hálózat, a rekurrens hálózat és az autoregresszív komponens erősségeinek kombinálásával az LSTM módszer jelentősen javítja az előrejelzési eredményeket. Így tehát az LSTM módszer ígéretes alternatíva a mezőgazdasági határidős árupiacok többváltozós idősorainak előrejelzésére. Liang és Jia (2022) a kukorica, szójabab, tojás, PVC és betonacél árait elemezték egyszerű és hibrid eszközökkel egyaránt. Az eredmények azt mutatták, hogy a GWO-CNN-LSTM modell jelentős

teljesítmény növekedést ért el a jövőbeli árak előrejelzésében. Ez a hibrid modell hatékonyan képes felismerni a mintázatot a határidős árfolyamok alakulásában, így nagy segítség lehet a kormányzati és piaci szereplőknek egyaránt. Ezen túlmenően a határidős piac szélsőséges volatilitásának kezelésére is kiváló eszköz. Weng és szerzőtársai (2019) az uborka árának alakulásával foglalkoztak a kínai piacon. Az eredmények alátámasztották, hogy az RNN módszer a legnagyobb pontosságot adó algoritmus. Megállapították tovább, hogy az ARIMA modell nagyon jó teljesítményre képes abban az esetben, ha az adatok erős periodicitással rendelkeznek. A szociális érzékelő („webcrawler”) által hozott adatskála bővülésének köszönhetően a mélytanulási módszerek ígéretes eredményt hoznak az árfolyam előrejelzésben, ami nagyon hasznos a vetésterület tervezésében. Deina et al. (2022) az arabica és a robusta kávé árfolyamának alakulását vizsgálták AR, ARIMA, MLP és ELM modellekkel. Az eredmények azt mutatták, hogy az ELM-et alkalmazó módszertan minden lineáris eljárást felülmúlt és az esetek 71%-ában jobbnak bizonyult, mint az MLP. A lineáris modellek alkalmazása egyszerű, de mivel az elemzett adatok meglehetősen változók, ezért az ANN-ek pontosabb előrejelzési eredményeket mutattak mindkét adatkészletre.

A szakirodalmi gyűjtés alapján megállapítható, hogy a leggyakrabban használt adatbázishossz (15. ábra) az árupiacok esetében az 1-10 és a 11-20 évig terjedő intervallum. A 11-20 és a 31-40 év közötti kategóriákba sorolhatók még a vizsgált publikációk.




15. ábra: Publikációk megoszlása az adatbázisok hossza alapján az árupiacok esetében (év)
(n=24)

Forrás: saját szerkesztés

Liang és kutatócsoportja (2023) a crude és a brent olajjal foglalkoztak. Az általuk javasolt DNPP (Dynamic Noisy Proximal Policy) algoritmus jól teljesített a nyersolaj árának előrejelzésében. Más

korszerű algoritmusokkal összehasonlítva a DNPP a teljesítményértékelési mutatók, a pontosság és a tényleges értékingadozások ábrázolása tekintetében kiemelkedő előnnyel rendelkezik. Sadefo Kamdem et al. (2020) a brent és crude olaj, búza és ezüst árfolyamait elemezték ARIMA és LSTM eszközökkel. Arra a következtetésre jutottak, hogy az LSTM modell jobban működik az árupiaci előrejelzésekben. Megállapították tovább, hogy a Covid19 időszakban a magasabb volatilitás miatt mindkét modell teljesítménye csökkent. Urolagin és szerzőtársai (2021) az arany és a crude olaj árának alakulását elemezte LSTM és hibrid módszerekkel (RMT-LSTM, RZT-LSTM). Az általuk fejlesztett hibrid modell az RZT-LSTM nagyon jól kezeli a kiugró értékeket és a magyarázó változók kiválasztásában is kiemelkedik, ami jelentős teljesítmény javulást eredményezett az egyszerű LSTM-hez képest. Xu et al. (2023) a crude olaj, brent olaj, arany, ezüst, platina, palládium és ródiium empirikus elemzésével foglalkoztak. Az eredmények azt mutatták, hogy a kutatók által javasolt GINN (Generalized Improved Hybrid Neural Network) modell teljesítménye a legjobb. A meglévő modellek összehasonlításából kiderült az is, hogy a neurális hálózatok általános teljesítménye jobb, mint az ökonometriai modelleké. Niu et al. (2020) a crude olaj árfolyamelemzésével kísérleteztek. Megállapították, hogy az általuk javasolt módszer (VMD-CNN-GRU) a referenciamodellekhez képest (Wavelet Neural Network (WNN), Generalized Regression Neural Network (GRNN), CNN-GRU, EMD-CNN-GRU) nagyobb pontossággal képes az olajárat előrejelezni. Guliyev és Mustafayev (2022) szintén a crude olajat vizsgálták csak más módszereket alkalmaztak (logisztikus regresszió, DT, RF, Adaboost, XGBoost). Eredményeik alátámasztották, hogy az XGBoost minden egyes mérőszám tekintetében felülmúlta a többi. A Random Forest a második helyen végzett. Megállapították tovább, hogy az XGBoost modell a DeLong-teszt alapján statisztikailag nem különbözik a Random Forest modelltől a teljesítmény tekintetében, így mindkettő használható előrejelzésre. A két említett tanulmányhoz hasonlóan Wang és kutatócsoportja (2020) is a crude olaj idősorával kísérletezett. Vegyesen használtak egyedi (LR, SVR, ANN) és hibrid modelleket (ABC-SVR). Arra a következtetésre jutottak, hogy az egyedi modellek teljesítménye tovább javítható, ha olyan hibrid módszereket alkalmaznak, amelyek segítséget nyújtanak az optimális magyarázó változók kiválasztásában. A vizsgált modellkombinációk közül a ABC-SVR bizonyult a legmegbízhatóbbnak.

Az árupiacokkal kapcsolatos szakirodalom vizsgálata során (16. ábra) az alkalmazott módszertanok viszonylatában a SVR a legtöbb alkalommal kiválasztott prediktív modell. Ahogy a korábbi termékkategóriák esetében itt is népszerű a LSTM, valamint a RF, ami a gépi tanulási algoritmusokat illeti és az összehasonlítás miatt kiemelt szerepet kapott az ARIMA modell is.




16. ábra: Top 10 alkalmazott módszertan az áru piacok esetében

Forrás: saját szerkesztés

Čeperić munkatársai (2017) a természetes gáz, fűtőolaj, crude olaj és a szén árának alakulását elemezte gépi tanulási és autoregresszív módszertanokkal. A tesztelt SSA-SVR modellek mindegyike lényegesen jobb eredményeket ért el, mint az FS (változók kiválasztása) megközelítés nélküli SVR modell. Az FS-algoritmusok használatának igen jelentős előnye látható az NN-modellek futtatásakor is. Zheng et al. (2023) a természetes gáz árfolyamváltozását vizsgálták és náluk is az SVR módszer volt az algoritmus fejlesztés alapja. Az eredmények azt mutatják, hogy a genetikai algoritmus használata az SVR hiperparamétereinek kiválasztásához jelentősen javítja a földgázár-előrejelzések pontosságát. Az orosz-ukrán konfliktus idején az FS-GA-SVR hibrid modell konzisztensebb és pontosabb előrejelzéseket mutat a földgáz azonnali árfolyamára vonatkozóan, mint az alap SVR modell. Wang kutatótársaival együtt (2021) szintén a természetes gáz árfolyamelemzésével foglalkoztak, azonban még a háborús konfliktus kitörése előtti időszakban, melyhez 23 különféle modellt alkalmaztak. Az eredmények azt mutatják, hogy az általuk javasolt új hibrid modell (CEEMDAN-SE-PSO-ALSGRU) nagy pontossággal tudja előrejelezni a földgáz heti árát.

A szakirodalmi adatbázis alapján a modellek értékelésére leggyakrabban használt teljesítményértékelési mutató az áru piacok esetén is az RMSE (17. ábra), melyet a MAE és a MAPE követ.



17. ábra: Top 5 teljesítményértékelési mérőszám az áru piacok esetében

Forrás: saját szerkesztés

Az áru piacok, különösen az energia- és nemesfém-szegmensek (pl. olaj, arany, ezüst), aránytalanul kevés figyelmet kaptak a gépi tanulási szakirodalomban, összevetve a részvény- vagy kriptovaluta piacokkal. Bár egyes tanulmányok alkalmaznak RNN-, LSTM- vagy SVR-alapú modelleket áru piaci adatok előrejelzésére, ezek gyakran leegyszerűsített keretekben mozognak: az inputváltozók többnyire múltbéli árfolyam-adatokra vagy alapvető technikai indikátorokra korlátozódnak. A legtöbb kutatás figyelmen kívül hagyja a globális makrogazdasági, politikai és környezeti hatásokat annak ellenére, hogy ezek különösen az áru piacokon kulcsszerepet játszanak. Az olaj- és földgázárak például szoros kapcsolatban állnak a geopolitikai feszültségekkel, kereskedelmi háborúkkal vagy termelési kvótákkal (pl. OPEC-döntések). Az arany ára gyakran menekülőeszközként reagál pénzügyi válságokra, inflációra vagy geopolitikai instabilitásra. E tényezők figyelmen kívül hagyása a modellek gyakorlati alkalmazhatóságát jelentősen csökkenti. Ezen túlmenően, a modellek validálása sokszor statikus (pl. egyetlen train-test split), így nem biztosított a prediktív teljesítmény folyamatos mérése változó piaci környezetekben. A válságidőszakokra történő kifejezett validáció (Covid-időszak vagy orosz-ukrán konfliktus) ritkán jelenik meg a publikációkban. Nem túl gyakori, hogy a kutatók megvizsgálják modell működését eltérő áru piaci eszközökön (pl. olaj vs. réz), így az általánosíthatóság is kérdéses. Ezáltal az áru piac továbbra is feltérképezetlen terep marad a prediktív modellezés szempontjából.


2.5.3. Kriptovaluta előrejelzések

Sun és kutatótársai (2020) 42 különböző kriptovaluta trendjének alakulását vizsgálták 2018. január és június között a Light Gradient Boosting Machine (LightGBM), Support Vector Machine és a Random Forest algoritmusok segítségével. A modellspecifikációk során 40 különféle

funkcióváltozót is felhasználtak. Azt tapasztalták, hogy LightGBM robosztusság szempontjából túlteljesítette a másik két modellt. Wang és munkatársai (2022) 12 különböző kriptovaluta hozamának előrejelezhetőségét vizsgálták 2017. augusztus és 2021. március között, a Random Forest, a logisztikus regresszió, a Support Vector Machine, az LSTM és az ANN modellekkel. Arra a következtetésre jutottak, hogy az Long Short-Term Memory algoritmussal sikerült elérni a legjobb becslési pontosságot. Megállapították továbbá, hogy a kereskedéssel kapcsolatos funkcióváltozók bevonásával csak az LSTM teljesítménye volt jelentős mértékben javítható. Oyedele és kutatótársai (2023) 6 különböző kriptovaluta záróárfolyamainak előrejelzését modellezték az Adaptive Boosting (ADABOOST), a Gradient Boosting Machines (GBM), Extreme Gradient Boosting (XGB), a Deep Feedforward Neural Networks (DFNN), a Gated Recurrent Units (GRU), Convolutional Neural Networks (CNN) segítségével. Eredményeik alapján a Convolutional Neural Networks teljesített a legjobban a becslési pontosság és a konzisztencia tekintetében egyaránt. Akyildirim et al. (2021) 12 kriptovaluta árfolyamainak előrejelezhetőségét elemezték, Support Vector Regression, logisztikus regresszió, Random Forest és ANN modellekkel a 2013. április és 2018. június közötti időszakban. Eredményeik alapján a SVR bizonyult a leginkább használható módszernek. Borges és Neves (2020) is hasonló következtetésre jutott a legjobb modell teljesítménye tekintetében. A szerzőpáros számos kriptovaluta árfolyamait elemezte technikai indikátorok és gépi tanulási algoritmusok (logisztikus regresszió, Random Forest, Support Vector Regression és Gradient Tree Boosting) segítségével. Esetükben is az SVR bizonyult a leghatékonyabbnak és azt is megállapították, hogy az ML módszertanok kereskedési stratégiákban való alkalmazásával nagyobb megtérülés érhető el, mint a buy-and-hold megközelítéssel. Zhang et al. (2021) tanulmányukban ARIMA, Random Forest, XGBoost, MLP, LSTM, GRU, CNN, illetve hibrid modellek (LSTM+CNN, GRU+CNN, WAMC - Weighted & Attentive Memory Channels) összehasonlítását végezték el 6 különféle kriptovaluta árfolyamainak előrejelzésére vonatkozóan. Ők arra a következtetésre jutottak, hogy a jól megépített hibrid módszerek tovább képesek javítani a prediktív teljesítményt és az általuk javasolt WAMC algoritmus bizonyult a legjobbnak. Alonso-Monsalve és szerzőtársai (2020) 6 népszerű kriptovaluta rövid-távú trendelemzésével foglalkoztak. A modellezés alapját a Convolutional Neural Network, a CNN-LSTM hibrid, a Multilayer Perceptron és az Radial Basis Function Neural Networks módszertanok képezték. A hibrid architektúra eredményei mindig jelentősen jobbak voltak a többinél és ez volt az egyetlen, amely a Dash és a Ripple trendjeit a legkisebb hibával (kb. 4%) tudta előrejelezni.

A feldolgozott publikációk kriptovaluta szekciójában jól látható (18. ábra), hogy a legnépszerűbb a Bitcoin, melyet az Ethereum és a Litecoin követ. A Bitcoin megjelenését tekintve az első és mai napig piacvezetően tekinthető (piaci kapitalizáció alapján). Mivel a kriptovaluták más pénzügyi

termékekhez viszonyítva újdonságnak tekinthetők, viszont meglehetősen populáris kutatási területről beszélhetünk, hiszen az utóbbi években rendkívül meggyarapodott a témával kapcsolatos tudományos publikációk száma.



18. ábra: Top 5 kripto valuta (n=27)

Az adatok 27 publikációra vetítve vannak, de egy kripto valuta több cikkben is megjelenhet.

Forrás: saját szerkesztés

A Bitcoin a tudományos kutatások területén is népszerűnek számít, ugyanis a legtöbb kripto valutával foglalkozó publikációban megjelenik. Cavalli és Amoretti (2021) tanulmányukban a Bitcoin trendjének alakulását próbálták előrejelezni 2013. április és 2020. február közötti árfolyam adatok felhasználásával. A modellezéshez az LSTM és a CNN (Convolutional Neural Network) algoritmusokat használták. Megállapították, hogy a CNN jobb becslési pontosságot ért el, mint az LSTM.

A következő tanulmányok mindegyike az LSTM modell eredményeit hangsúlyozza a Bitcoin árfolyamának előrejelzése során. Chen és munkatársai (2020) a Bitcoin árfolyam előrejelzését vizsgálták a logisztikus regresszió, a lineáris diszkriminancia-elemzés, a Random Forest (RF), az XGBoost, a kvadratikus diszkriminancia-elemzés, a Support Vector Machine (SVM) és az LSTM modellek segítségével. Arra a következtetésre jutottak, hogy az 5 perces árfolyam adatok esetében az LSTM nyújtotta a legjobb becslési teljesítményt, míg napi árfolyam adatokkal végzett modellezésnél a logisztikus regresszió végzett az első helyen. Jaquart et al. (2021) a Feedforward Neural Networks, az LSTM (Long Short-Term Memory), a GRU, a Random Forest és a Gradient Boosting modellekkel vizsgálták a Bitcoin árfolyam mozgásainak irányát rövid távon. Azt tapasztalták, hogy a LSTM képes a legnagyobb pontosságú becslésre. A technikai, blokklánc-alapú, érzelmi/érdekalapú és eszközalapú jellemzőcsoportok összehasonlítása azt mutatja, hogy a


legtöbb módszer esetében a technikai jellemzők továbbra is túlnyomórészt fontosak. Hosszabb előrejelzési horizontok esetén úgy tűnik, hogy a relatív fontosság több jellemző között oszlik meg (másodpercenkénti tranzakciók, súlyozott érzelmek, stb.). Alkhodhairi és szerzőtársai (2021) a Bitcoin nyitó, legmagasabb, legalacsonyabb és záró árának alakulását igyekeztek megbecsülni deep learning eszközökkel (LSTM, GRU). Vizsgálatuk során 4, 12, 24 órás előrejelzéseket modelleztek. Megállapították, hogy a legjobb teljesítményt az LSTM produkálta. Chen et al. (2021) tanulmányukban a Bitcoin árfolyamelőrejelzésével foglalkoztak. Az elemzésükben a Random Forest, az Artificial Neural Network (ANN), az LSTM, az ARIMA, az SVM, az adaptív hálózati fuzzy inferencia rendszer (ANFIS), valamint a Genetic Algorithm (GA) modelleket használták. Eredményeik alapján az LSTM volt a legnagyobb pontossággal becselő modell. Azt is megállapították, hogy a különféle prediktív algoritmusok jobban teljesítenek, ha funkcióváltozókat vonnak be a modellfejlesztési folyamatba. Mudassir és munkatársai (2020) a Bitcoin árfolyamának előrejelzésével foglalkoztak. Elemzésükhöz 4 gépi tanulási módszert használtak (Artificial Neural Network, Stacked Artificial Neural Network, Support Vector Machine (SVM) és az Long Short-Term Memory (LSTM). Eredményeink azt mutatják, hogy a BTC tényleges árfolyamát nagyon alacsony hibaarányal lehet előre jelezni, míg az emelkedését és csökkenését sokkal nehezebb. A bemutatott osztályozási modell (LSTM) teljesítményeredményei a legjobbak a szakirodalomban.

Mallqui és Fernandes (2019) a Bitcoin maximum, minimum és záróárának előrejelezhetőségét vizsgálták a Multilayer Perceptron és a Support Vector Regression modellek segítségével. Eredményeik azt mutatják, hogy az SVR algoritmus adja a pontosabb előrejelzést. Megállapították továbbá, hogy az általuk kiválasztott attribútumok és a legjobb gépi tanulási modell több mint 10%-os javulást ért el az árfolyam-előrejelzések pontosságában, a korábbi tanulmányokban bemutatott módszertanokhoz viszonyítva. Jang és Lee (2017) több termék között a Bitcoin árfolyamának alakulását és annak előrejelezhetőségét elemezték a lineáris regresszió, a Bayesian Neural Networks és a Support Vector Machine módszertanokkal. A prediktív teljesítmény alapján ők viszont arra a következtetésre jutottak, hogy a Bayesian modell a legalkalmasabb a három közül. Al-Nefaie és Aldhyani (2022) a Bitcoin árfolyam előrejelezhetőségét modellezték a Gated Recurrent Unit (GRU) és a Multilayer Perceptron (MLP) algoritmusok segítségével, 2021. január és 2022. júniusa között. Azt találták, hogy az MLP minimálisan, de jobb teljesítményre volt képes, mint a GRU modell. Ezek az eredmények jelentősen befolyásolhatják az eszközárak megfelelőségét, figyelembe véve a digitális valuták okozta bizonytalanságokat.

Cocco et al. (2021) a Bitcoin árfolyamának előrejelezhetőségét modellezték a tanulmányukban a Bayesian Neural Network, a Feed Forward és a Long-Short Term Memory Neural Network, a Support Vector Machine, valamint hibrid algoritmusokat felhasználva. Azt találták, hogy a

kombinált modellek növelik a prediktív teljesítményt. Tapia és Kristjanpoller (2022) a Bitcoin volatilitásának előrejelzésére ökonometriai, gépi tanulási, valamint hibrid modelleket alkalmaztak. Arra a következtetésre jutottak, hogy az AMEM (Asymmetric Multiplicative Error Model) és az LSTM kombinálása jelentősen növeli a becslési pontosságot. Dutta és szerzőtársai (2020) tanulmányukban a GRU és LSTM modelleket hasonlították össze, melyhez a Bitcoin árfolyamalakulását használták. Az általuk alkalmazott és javasolt GRU rekurrens szelekcióval feljavított hibrid modell pontosabbnak bizonyult a többi algoritmusnál.

A szakirodalmi gyűjtés alapján megállapítható, hogy a leggyakrabban használt adatbázishossz (19. ábra) a kriptovaluták esetében az 1-10 évig terjedő intervallum. A 11-20 év közötti kategóriában pedig egy publikáció található. Mivel a kriptopiac története 15 éves időtávra nyúlik vissza ezért a hosszabbtávú elemzésnek nem lehet létjogosultsága. Illetve a piac volatilitásából adódóan is jellemzően inkább a rövidebb távú előrejelzésre koncentrálnak.




19. ábra: Publikációk megoszlása az adatbázisok hossza alapján a kriptovaluták esetében (év) (n=27)

Forrás: saját szerkesztés

Lahmiri és Bekiros (2019) a Bitcoin, a Digital Cash és a Ripple árfolyamelőrejelzésének vizsgálatára az LSTM és a GRNN (Generalized Regression Neural Networks) modelleket alkalmazták. Megállapították, hogy a hosszú-rövid távú memória neurális hálózati topológiák (LSTM) előrejelzőképessége jelentősen nagyobb, mint a referenciaként használt általános regressziós neurális architektúráé. Bár az LSTM-modell számítási terhe magasabb a nyers, nemlineáris mintafelismerésben, végül a mélytanulás rendkívül hatékonynak bizonyult a kriptopiacok eredendően kaotikus dinamikájának előrejelzésében. Serrano (2022) a Bitcoin, az Ethereum és a Ripple árfolyamainak előrejelzésére a Random Neural Network (RNN), az LSTM

és a lineáris regresszió modelleket használta. Az összehasonlítás arra az eredményre vezetett, hogy az NN algoritmusok nagyon hasonló teljesítményt mutattak és mindegyik felülmúlta az LR-t. Hasonló eredményre jutott Uras és kutatótársai (2020), akik szintén a Bitcoin, az Ethereum és a Litecoin árfolyamváltozásait és azok előrejelezhetőségét vették górcső alá. Az elemzéseikhez a lineáris regresszió és az LSTM modellek egy (csak záróárak) és többváltozós (volumen, legmagasabb és legalacsonyabb ár) típusait használták. Azt állapították meg, hogy az Ethereum és a Litecoin könnyebben prediktálhatóak, mint a Bitcoin. Összességében az egyváltozós LSTM modell teljesített a legjobban. A szerzők arra is felhívják a figyelmet, hogy a modellfuttatási idők között jelentős differencia volt a regressziós modellek javára. Sebastião és Godinho (2021) a Bitcoin, az Ethereum és a Litecoin árfolyamszintjeit vizsgálták a 2015. augusztus és 2019. március közötti időszakban. A módszertan alapját a lineáris regresszió, a Random Forest és a Support Vector Machine képezte, melyeket konkrét kereskedési stratégiákká konvertáltak. Esetükben azonban meglepetésre a lineáris regresszió hozta a legjobb eredményeket. Megállapították továbbá, hogy az előrejelzések leginkább az Ethereum és a Litecoin esetén működtek.

A kriptovalutákkal kapcsolatos szakirodalom vizsgálata során (20. ábra) az alkalmazott módszertanok tekintetében az LSTM a legtöbb alkalommal előforduló prediktív modell. Összességében elmondható, hogy a mélytanulási modellek (LSTM, GRU) kiemelkedő előrejelzési teljesítményére szükség is van, mivel a jelentős volatilitással rendelkező kriptopiaci mozgásokat az egyszerűbb algoritmusok sokkal nehezebben tudják megbecsülni.



20. ábra: Top 10 alkalmazott módszertan a kriptovaluták esetében


Forrás: saját szerkesztés

Poongodi et al. (2020) tanulmányukban az Ethereum árfolyamának előrejelzésére a lineáris regresszió (LR) és a support vector machine modelleket alkalmazták. Arra a következtetésre

jutotta, hogy az SVM sokkal nagyobb pontosságú becslési eredményre képes, mint az LR. Zoumpakas et al. (2020) szintén az Ethereum árfolyamát vizsgálták neurális hálós (CNN, LSTM, SLSTM, BiLSTM, GRU) modellek segítségével. Ők azt tapasztalták, hogy a hagyományos LSTM algoritmus a legalkalmasabb az általuk használt árfolyam adatok előrejelzésére.

Patel és szerzőtársai (2020) a Litecoin és a Monero kriptovaluták árfolyamainak előrejelezhetőségét vizsgálták 1, 3 és 7 napos becslési periódusokra vonatkozóan. Az általuk alkalmazott és javasolt GRU-LSTM hibrid modell pontosabbnak bizonyult a hagyományos LSTM algoritmusnál. Peng és szerzőtársai (2018) pedig a Bitcoin, Ethereum és a Dash volatilitásának előrejelezhetőségét vizsgálták GARCH, SVR és hibrid modellekkel. Az elemzésükben a SVR-GARCH hibrid megközelítési módszer az összes többi modellnél hatékonyabbnak bizonyult.

A szakirodalmi adatbázis alapján kiderült, hogy a modellek értékelésére leggyakrabban használt teljesítményértékelési mutató a kriptovaluták esetén is az RMSE (21. ábra), melyet a klasszifikáció esetén használt Accuracy és a MAPE követ.



21. ábra: Top 5 teljesítményértékelési mérőszám a kriptovaluták esetében

Forrás: saját szerkesztés

A kriptovaluta-piacokra alkalmazott gépi tanulási modellek az elmúlt években jelentős figyelmet kaptak, különösen az LSTM, CNN, valamint különféle hibrid architektúrák formájában. A szakirodalom gyakran demonstrálja ezek kiemelkedő pontosságát rövid időtávokon, ugyanakkor az alkalmazások nagy része figyelmen kívül hagyja a kriptopiacokra jellemző, rendkívül erős volatilitást, strukturális töréspontokat és árfolyam-buborékokat. Ennek eredményeképp a modellek predikciós teljesítménye nem kellően rezsimérzékeny: azaz nem világos, hogy normál piaci környezetben és például összeomlási időszakban mennyire különböző eredményt hoznak.


Emellett a metrikák önmagukban nem biztosítják az értelmezhetőséget, mivel a kriptoeszközök árszintje órákon belül akár 20–30%-ot is változhat. Ezek a szélsőségek torzíthatják a metrikák jelentését, miközben a modellek finomhangolása ritkán történik robusztus scenáriókkal. Illetve az előrejelzések mögött nincs valódi kereskedési koncepció, amely alapján megítélhető lenne a modellek valós gyakorlati teljesítménye. A kutatások továbbá kevésbé foglalkoznak azzal, hogy egy adott modell hogyan teljesít különböző kriptoeszközökön (pl. Bitcoin vs. altcoinok), illetve hogyan változik a prediktív teljesítmény a piaci ciklusok függvényében. Ez különösen kritikus, mivel a kriptopiac decentralizált és szabályozatlan jellege miatt a piaci viselkedés szinte időről időre újratanulást igényelhet. A terület tehát kiváló lehetőséget kínálna a reziliencia- és volatilitásérzékeny algoritmusok tesztelésére, de ezt a lehetőséget az irodalom még csak részben aknázza ki.

2.5.4. Devizapiaci előrejelzések

Islam és Hossain (2020) az EUR-USD, GBP-USD, USD-CAD és USD-CHF devizakereszték árfolyamalakulását modellezte az LSTM, GRU és GRU-LSTM mély tanulási módszerek segítségével. A kísérleti eredmények azt mutatták, hogy a GRU-LSTM hibrid modell pontosabban jelezte előre a vizsgált devizák keresztárfolyamát, mint a két legnépszerűbb és legmegbízhatóbb idősoralelemző neurális hálózati módszer (LSTM és GRU). Yıldırım és kutatócsoportja (2021) az EUR-USD keresztet használták a modellkísérleteikhez. Az alkalmazott módszerek tekintetében csak az LSTM-et és annak különböző változataival dolgoztak ME-LSTM (makro adatok magyarázó változóként), TI-LSTM (technikai indikátorok magyarázó változóként). Megfigyelték, hogy a technikai indikátorokhoz képest a makro adatokkal kombinált modell valamivel jobb teljesítményt nyújtott a pontosság tekintetében. A különbség azonban nagyon kicsi és jelentéktelen volt. Továbbá az összes jellemző (makro adatok és technikai indikátorok) egyetlen LSTM modellbe történő egyesítése nem növelte jelentősen a pontosságot. Ahmed et al. (2020) tanulmánya szintén az EUR-USD-ot vizsgálja, viszont szélesebb modellpalettával (ARIMA, RNN, LSTM, FLF-RNN, FLF-LSTM) Az általuk javasolt FLF-LSTM (Forex Loss Function-LSTM) algoritmus minden más modell teljesítményét felülmúlta. Escudero et al. (2021) is az EUR-USD-ot tanulmányozta, melyhez az ARIMA, ENN (Elman NN) és LSTM eszközöket használták. Az összehasonlítás során megállapították, hogy az ARIMA állandó számokat generált, míg az LSTM rövid távon 22 napos időtartamra a legjobb előrejelzést adta. Az Elman modellel azonban a hosszú távú előrejelzések bizonyultak jobbnak. A fentiekkel ellentétben akadnak kutatók, akik az SVR módszert részesítik előnyben. Jubert de Almeida és kutatótársai (2018) az EUR-USD-ot vizsgálták a SVR, GA és GA-SVR módszerek felhasználásával. Az eredményeik alapján megállapították, hogy a hibrid rendszer használata, amely kombinálja az SVR-t és a GA-t

egy új megközelítést biztosít a devizakereskedéshez, ahol nagyobb pontossággal osztályozhatók a trendek. A kombinált metódusok előnyeit hangsúlyozza Sadeghi és szerzőtársainak (2021) tanulmánya is, amelyben az EUR-USD árfolyamváltozásával kapcsolatosan arra a következtetésre jutottak, hogy a javasolt EMC-SVR modell hatékonyabbnak bizonyult az emelkedő, oldalazó és csökkenő trendek felismerésében is, mint az egyszerű SVR.

A devizakeresztek tekintetében a legkedveltebb eszköznek az EUR-USD bizonyult (22. ábra), ami a szisztematikus szakirodalmi adatbázis alapján. A kutatómunka során megállapítottam azt is, hogy a 4 fő terület közül a devizapiac az, amely a legkevésbé kutatott, legalábbis ami a prediktív modellezést illeti. (Az adatok 16 publikációra vetítve vannak, de egy devizapár több cikkben is megjelenhet.)



22. ábra: Top 5 devizakereszt (n=16)


Az adatok 16 publikációra vetítve vannak, de egy devizapár több cikkben is megjelenhet.

Forrás: saját szerkesztés

Ni et al. (2019) az EUR-USD, AUD-USD, GBP-JPY, EUR-JPY, GBP-USD, USD-CHF, USD-JPY és az USD-CAD devizapárokkal kísérleteztek, melyhez három modellt használtak (CNN, LSTM, CNN-RNN). A gyakorlati tapasztalatok azt mutatták, hogy a hibrid CNN-RNN modell sokkal jobb előrejelzési teljesítményre képes a másik kettőhöz viszonyítva. Lin és kutatótársai (2020) az USD-AUD árfolyam-ingadozásait tanulmányozta 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. Dautel és kutatócsapata (2020) az EUR-USD, GBP-USD, JPY-USD és a CHF-USD árfolyamalakulását tanulmányozta. Felhívták a figyelmet, hogy a kutatás során az LSTM és a GRU koncepcionális előnyei érvényesültek a hagyományosabb RNN-ekhez képest, ami kiváló

előrejelzési teljesítményt eredményezett. Ugyanakkor azt is megfigyelték, hogy a hagyományos FFNN-ek szintén versenyképesek voltak és a teljesítménybeli különbségek nem bizonyultak jelentősnek. Abedin munkatársaival (2021) 21 devizakeresztet elemeztek a Lasso regresszió, Ridge regresszió, DT, SVR, RF, LSTM, Bi-LSTM, Bagging regresszió (mely kombinálja a különféle regressziós modelleket a variancia minimumon tartásával) és a Bi-LSTM-BR alkalmazásával. Az általuk javasolt Bi-LSTM-BR hibrid mélytanulási megközelítés kiváló előrejelzési hatékonysággal rendelkezik a vizsgálatba bevont többi algoritmussal szemben. Az eredmények arra utalnak, hogy általában véve az alkalmazott modell előrejelzési teljesítménye romlott a Covid19 időszak alatt. A teljesítmény különösen a leginkább hátrányosan érintett országok árfolyamai esetében romlott és ez a világjárvány által kiváltott nagyobb volatilitásnak tulajdonítható.

A szakirodalmi gyűjtés alapján megállapítható, hogy a leggyakrabban használt adatbázishossz (23. ábra) az 1-10 és a 11-20 évig terjedő intervallum kategóriákba esik. Ez az egyetlen olyan termékcsoport, ahol a nagyon hosszútávnak számító 41-50 év közötti időszakot is figyelembe veszik az előrejelzési modellek bemeneti adatainál.




23. ábra: Publikációk megoszlása az adatbázisok hossza alapján a devizapiacok esetében (év) (n=16)

Forrás: saját szerkesztés

Qi és szerzőtársai (2020) a GBP-USD, EUR-GBP, AUD-USD és a CAD-CHF devizakeresztet elemezték mély tanulási modellekkel (RNN, LSTM, Bi-LSTM, GRU). A kísérleti eredményeink azt mutatták, hogy a javasolt eseményvezérelt magyarázó változók kiválasztása a Bi-LSTM modellel együtt olyan robusztus előrejelző rendszert alkothat, amely minimális kockázat mellett támogatja a pontos kereskedési stratégiák kialakítását. Rundo (2019) publikációjában az EUR-

USD, GBP-USD és az EUR-GBP devizakeresztek alakulásával foglalkozott. Az LSTM, LSTM-RL (reinforcement learning correction block) módszertant hasonlított össze. A kutató megállapította, hogy az LSTM-RL hibrid modell sokkal hatékonyabban képes a devizakeresztek trendjeit felismerni, mint az egyszerű LSTM. Baffour et al. (2019) 5 különböző keresztárfolyamot vizsgált (AUD-USD, CAD-USD, CHF-USD, EUR-USD, GBP-USD) az ANN-GJR, GARCH és APGARCH segítségével. Az empirikus bizonyítékok azt sugallták, hogy a kifejlesztett hibrid ANN-GJR figyelemre méltóan felülmúlja az összes alkalmazott referencia-modellt.

A devizapiacokkal kapcsolatos szakirodalom vizsgálata során (24. ábra) az alkalmazott módszertanok tekintetében kiemelt szerepet kapnak a mélytanulási módszerek, melyek közül az LSTM a leggyakrabban használt prediktív modell. Fontos megemlíteni, hogy a devizakeresztekkel kapcsolatos modellezéshez a legtöbbször valamilyen hibrid módszer is az összehasonlítás alapját képezi és több esetben ezek bizonyulnak a leghatékonyabbnak.




24. ábra: Top 10 alkalmazott módszertan a devizapiacok esetében

Forrás: saját szerkesztés

Xueling és szerzőtársai (2023) a CNN, LSTM, GRU, XGBoost-LSTM, CNN-Bi-LSTM-AM és CNN-LSTM gépi és mély tanulási módszertanokkal elemezték az AUD-RMB, EUR-RMB, USD-RMB és a RMB-JPY árfolyamváltozását. A kísérletek eredményei azt mutatják, hogy a kutatók által javasolt CNN-LSTM modell minden más módszernél hatékonyabbnak bizonyult a vizsgált devizakeresztek trendjeinek előrejelzésében. Más eredményre jutott Sako et al. (2022), akik mély tanulási eszközökkel (RNN, LSTM, GRU) modellezték a ZAR-USD, NGN-USD, GBP-USD, EUR-USD, RMB-USD és a JPY-USD devizakeresztek árfolyamalakulását. Az elemzés és összehasonlítás eredményeként, valamint a modellspecifikáció alapján megállapítható, hogy a GRU a legjobb, a devizaárfolyamok egy- és többváltozós előrejelzéséhez egyaránt. Cao et al.

(2020) az USD-CNY-t vizsgálta hagyományos és gépi tanulási módszerekkel (ARIMA, SVR, CNN, LSTM, DC-LSTM). A kísérleti eredmények azt mutatták, hogy a javasolt megközelítés jelentősen felülmúlja a hét másik algoritmust. A DC-LSTM (Deep Coupled-LSTM) hasznos eszköznek bizonyul a profitábilis befektetési döntések meghozatalához.

A szakirodalmi adatbázis alapján kiderült, hogy a modellek értékelésére leggyakrabban használt teljesítményértékelési mutató a MAE (25. ábra), melyet az RMSE követ.



25. ábra: Top 5 teljesítményértékelési mérőszám a devizapiacok esetében

Forrás: saját szerkesztés

A devizapiaci előrejelzések területén alkalmazott gépi tanulási modellek többnyire a technikai indikátorokra épülnek és olyan algoritmusokat alkalmaznak, mint az XGBoost, SVM, random forest vagy GRU. Ugyanakkor a legtöbb vizsgálat nem veszi kellően figyelembe a fundamentális gazdasági tényezőket, például a kamatlábkülönbségeket, központi banki politikákat, inflációs várakozásokat vagy geopolitikai eseményeket. Azonban ezek a devizaárfolyamok alakulásában hosszú távon kulcsszerepet játszanak. A vizsgált modellek általában nem tesznek különbséget eltérő piaci struktúrák között, pedig a modellek teljesítménye ezekben a szakaszokban jelentősen eltérhet. Ennek hiányában a prediktív értékek aggregáltak maradnak, így nehéz megállapítani, milyen környezetben működnek jól a modellek. Emellett a tanulmányok gyakran idealizált feltételezésekből indulnak ki: tranzakciós költségek, slippage (végrehajtási ár eltér attól az ártól, amelyen a kereskedési megbízást adták), likviditáskorlátok figyelmen kívül hagyása mellett értékelik a modellek teljesítményét. Ez torzított képet ad a gyakorlati alkalmazhatóságról, különösen olyan devizapároknál, ahol a spreadek alacsonyak, de a volumen és a kereskedési gyakoriság extrém magas. A valósidejű kereskedési környezetekben elkerülhetetlen piaci zaj és az algoritmusok adaptációs képessége ritkán kerül értékelésre. A modellek által nyújtott

iránybecslések sokszor nem kerülnek kereskedési stratégiákba ágyazva vizsgálatra, ami megnehezíti a teljesítmény mérését a befektetői döntéshozatal szintjén. A devizapiaci modellezés így továbbra is inkább elméleti síkon mozog és gyakran nem kapcsolódik közvetlenül a piaci gyakorlat realitásaihoz.

2.6. Szisztematikus szakirodalmi áttekintés összegzése

A szisztematikus szakirodalmi áttekintésem elkészítéséhez a Google Scholar, a Science Direct és a Web of Science adatbázist használtam. A 2014-2023. időszakban megjelent cikkekre fókuszáltam. A különféle finomhangolások után 2791 találat maradt. Ez a három kereső platform együttes eredménye. A duplikációk eltávolítása után 683 cikk maradt, majd ezekből a cím alapján 267 publikációra szűkítettem az adatbázist. További 157 tanulmány kikerült, mert ezek alacsonyabb minősítéssel rendelkező folyóiratokban jelentek meg. Összesen 110 tételre szűkült a keresési eredmény, amelyek közül további 10 darab szakirodalmi áttekintés jellegű volt, ezért a legvégén 100 publikációt mutattam be részletesen.

A szakirodalmi kutatás során sikerült részletesen feltérképezni a vizsgált témakört és választ kapni az előzetesen feltett kérdésekre. Elsőként az volt a legfontosabb megállapítás, hogy a tudományos publikációk között legnépszerűbb a részvénytőzsdák vizsgálata. Ezt a felépített publikációs adatbázis is alátámasztja, mivel ilyen típusú cikkből található a legtöbb. Nagyon felkapott továbbá a kriptovaluták piaca is, amely volatilitásuk miatt igazi kihívást jelent a modellek és a modellalkotók számára egyaránt. A második fontos konklúzió az volt, hogy a neurális hálózati modellek átvették a vezető szerepet az alkalmazott módszertanok tekintetében, melyek közül kiemelkedik az LSTM modell, amely a szakirodalmi adatbázisban a legtöbbször fordult elő. Kiemelném továbbá azt is, hogy a legtöbb esetben ez a módszer vagy ennek valamilyen hibrid változata volt az, amely a legpontosabb előrejelzési eredményeket adta. A szisztematikus szakirodalmi áttekintés által választ kaptam arra a kérdésre is, hogy melyek a legfontosabb teljesítményértékelési mérőszámok, amik nélkülözhetetlen a modellek összehasonlításánál. Az elemzett adatbázis alapján a leggyakrabban az RMSE (átlagos négyzetes hiba négyzetgyöke) mutatót használták. Meg kell említeni ugyanakkor, hogy a MAPE (átlagos abszolút százalékos hiba) szintén fontos szerepet kapott elsősorban a skálafüggetlensége miatt, mivel ezzel a mutatóval nemcsak a modelleket egymással, de a különféle termékkategóriák előrejelezhetőségének pontosságát is össze lehet hasonlítani. A modellezéshez használt adatbázisok hossza tekintetében azt a megállapítást tettem, hogy a leginkább az 1-10 év közötti intervallumot preferálják a kutatók. Illetve népszerű még a 11-20 éves periódus is. A kriptovaluták esetében természetesen a rövidebb időszakok tekinthetők irányadónak, mivel egy rendkívül fiatal kategóriáról beszélünk, amelynek gyökerei csak a 2009-es évig nyúlnak vissza. Az alkalmazott statisztikai módszerek esetében a

regresszió számít a legnépszerűbbnek a vizsgált adatbázis alapján, de akad számos olyan kutatás, amely a klasszifikációs módszert részesíti előnyben.

A szakirodalom feltérképezése után a kutatási kérdések vonatkozásában elmondható, hogy a legjobban és legnagyobb pontossággal a neurális hálózati modellek teljesítenek, melyek közül kiemelkedik az LSTM és a GRU. Megállapítható továbbá, hogy a gazdaságilag stresszes időszakok, mint a Covid19 vagy az orosz-ukrán háborús konfliktus negatívan hatnak a prediktív teljesítményre. Ugyanakkor relatív kevés olyan publikáció van, ahol a terméktípusok közötti összehasonlítást vizsgálják, tehát hogy melyik termék árfolyamát lehet nagyobb pontossággal előrejelezni. Jobbára inkább a modellek egymáshoz viszonyított hatékonyságára helyezik a hangsúlyt, ezért ez a terület mindenképpen egy kutatási résnek tekinthető. Nincs teljes konszenzus abban a kérdésben sem, hogy az egy- vagy többváltozós módszerek tekinthetők-e jobbnak. Hasonló a helyzet a hibrid modelleszettek alkalmazásával kapcsolatosan is, mivel egyes publikációk eredményei jobbnak, míg mások hasonlóknak, esetleg rosszabbnak ítélik az ilyen kombinált módszertanok teljesítményét.

2.7. Kutatási részek azonosítása

A szakirodalmi áttekintés során egyértelműen kirajzolódott, hogy bár a pénzügyi idősort előrejelző gépi tanulási modellek alkalmazása rendkívül intenzív kutatási terület, számos kritikus aspektusban hiányosság mutatkozik. Ezek azonosítása nem csupán az irodalom értelmezéséhez járul hozzá, hanem megalapozza a dolgozatom saját kutatási irányvonalát is. Az alábbiakban három kulcsfontosságú kutatási rést emelek ki.

1. Modellek gyakorlati alkalmazhatósága kereskedési stratégiákban

A legtöbb tanulmány az előrejelző modellek pontosságára fókuszál, jellemzően statikus metrikák (MAPE, RMSE, MAE) segítségével értékelve az eredményeket. Ugyanakkor ezek a modellek csak ritkán kerülnek beillesztésre konkrét, szimulált vagy valós kereskedési stratégiákba. Ezáltal nem vizsgálják a predikciók tényleges pénzügyi értékét. A modellek „elkülönítése” a gyakorlati alkalmazási kontextustól jelentős korlátot képez, különösen a nagy volatilitású vagy alacsony likviditású eszközök (pl. kriptovaluták, árupiacok) esetén. Ez alapján világosan azonosítható, hogy a predikciós modellek valódi hasznosíthatósága még alulkutatott területnek számít.

2. A volatilitás és predikciós teljesítménymutatók viszonya

A második kutatási rés a különböző pénzügyi termékek (részvények, árupiaci termékek, devizák és kriptovaluták) eltérő volatilitási sajátosságaira fókuszál és ezek hatására az előrejelző modellek teljesítményére. Bár a volatilitás a pénzügyi piacok egyik legfontosabb jellemzője, a gépi tanulási

modellek teljesítményét ritkán értékelik kifejezetten ennek tükrében. A magas volatilitású piacok például a kriptovaluták vagy bizonyos nyersanyagok kiszámíthatatlansága komoly kihívást jelent az algoritmusok stabilitása és megbízhatósága szempontjából, míg az alacsonyabb volatilitású eszközöknél más típusú hibák dominálhatnak. A szakirodalomban kevés olyan tanulmány található, amely szisztematikusan vizsgálja, hogy a különböző piaci instrumentumok eltérő volatilitási szintjei miként befolyásolják a modellek predikciós pontosságát, robusztusságát vagy általánosíthatóságát. Ennek a hiányosságnak a feltérképezése hozzájárulhat a volatilitás-érzékeny modellek fejlesztéséhez.

3. Modellek időbeli robusztussága és stabilitása eltérő piaci környezetekben

A harmadik jelentős kutatási rés a modellek időbeli robusztusságára vonatkozik. Számos kutatás használ egyszeri train-test felosztást és ritkán alkalmaz olyan időfüggő validációs technikákat, mint a gördülő ablak (rolling-window) vagy előremenő tesztelés (walk-forward). Ezek hiányában azonban nem állapítható meg, hogy egy modell teljesítménye stabil-e hosszabb távon, illetve különböző piaci ciklusokban (pl. válság, fellendülés, konszolidáció). Mivel a pénzügyi idősorok szinte kivétel nélkül nem-stacionáriusak és időfüggő struktúrával rendelkeznek, egy modell időbeli megbízhatósága alapvető fontosságú. Ezt a tényezőt jelenleg az irodalom jelentős része figyelmen kívül hagyja, ami szintén kutatási lehetőséget nyit az előrejelző algoritmusok értékelésének új dimenziója felé.

A fenti három kutatási rés közös metszéspontja az a felismerés, hogy a gépi tanulási modellek pénzügyi alkalmazása túlnyomórészt elméleti vagy szimulált keretek között történik, miközben hiányzik a robusztus, kontextusérzékeny értékelés. Ezen hiányosságok kezelése elősegítheti a modellek tényleges piaci alkalmazhatóságának jobb megértését, valamint megalapozhat egy olyan új értékelési keretrendszert, amely figyelembe veszi a volatilitás dinamikáját, a piaci rezsimeket és az időbeli stabilitást.

2.8. Az előrejelző modellek kereskedési stratégiákban történő alkalmazása

Az előrejelző modellek kereskedési stratégiákban történő alkalmazása még kiaknázatlan területnek számít, azonban akadnak tanulmányok, amelyek igyekeznek a gyakorlati alkalmazást is vizsgálni és népszerűsíteni a tanulmányokban. Alapvetően a részvény- és kriptovaluta piacokra fókuszálnak ezek a vizsgálatok, melyek közül néhányat részletesebben is bemutatok a következő szakaszban. Elsőként a részvényekre és részvényindexekre helyezve a hangsúlyt.

Pourahmadi et al. (2024) részvénykereskedési modelleket vizsgáltak, amelyek a megerősítő tanulást (Reinforcement Learning, RL) és a technikai elemzést kombinálják, figyelembe véve a tranzakciós költségeket. A szerzők rámutatnak az alap RL modellek korlátaira a zajos és

többdimenziós tőzsdei környezetben és egy módosított Actor-Critic alapú RL modellt javasolnak a probléma orvoslására. Az innováció abban rejlik, hogy az "actor" komponenst három technikai elemzési metrikával (Relative Strength Index, Stochastic Oscillator, és Moving Average Convergence Divergence) egészítik ki, hogy valószerűbb és hatékonyabb kereskedési stratégiákat hozzanak létre. A modell megbízhatóságát az S&P 500 index pénzügyi adatain végzett elemzésekkel ellenőrizték. Az eredmények jelentős javulást mutattak a hagyományos kereskedési stratégiákhoz képest. A javasolt modell 11,23%-os átlagos éves hozamot ért el szemben a "buy-and-hold" stratégia 1,57%-ával. Emellett a Sharpe-ráta is kimagasló volt, 0,444 a javasolt modellnél, szemben a "buy-and-hold" 0,057-es értékével. A statisztikai elemzések igazolják, hogy a technikai elemzés és az RL kombinációja felülmúlja a hagyományos passzív stratégiát. Zhou és munkatársai (2025) az ún. IFF-DRL-t (Incremental Forecast Fusion – Deep Reinforcement Learning) módszerrel kísérleteztek, amely ötvözi az inkrementális tanulást, az önfelügyelt (self-supervised) idősortanulást és a mély megerősítéses tanulást (DRL) a pénzügyi kereskedés optimalizálása érdekében. A modell először az AutoConNet nevű prediktív hálózattal előrejelzi az OHLCV (open, high, low, close, volume) idősorokat, majd ezeket a tényleges adatokkal kombinálva hoz létre napi és heti szintű inputot az RL modell számára. A kísérleteket tőzsdeindexen (Dow Jones, S&P500, Hangseng Index) hajtották végre a 2007-2023-as időszakra vonatkozóan. A módszer az online Elastic Weight Consolidation (EWC) algoritmust is alkalmazza a prediktív hálózat folyamatos frissítésére, így a modell hatékonyan alkalmazkodik a piaci rezsimék változásaihoz. Az eredmények kiemelkedőek ugyanis a Hangseng indexnél az évesített hozam elérte a 103,19%-ot, miközben a Sharpe-mutató és más kockázati mutatók is jelentős javulást mutattak a buy-and-hold stratégiához képest. A tanulmány egyértelműen demonstrálja, hogy az időben adaptív, jövőre fókuszáló előrejelzés integrálása a megerősítéses tanulásba érdemben javítja a kereskedési teljesítményt volatilis piaci környezetben. Ju, Shen és Ni (2025) tanulmányukban azt vizsgálták, hogy egy LSTM-alapú előrejelző modellre épített kereskedési stratégia képes-e szignifikáns többlethozamot generálni a hagyományos „buy and hold” stratégiához képest. A szerzők backtest-alapú teljesítményértékelést végeztek több amerikai részvényre vonatkozóan és az eredményeket hozam, Sharpe-mutató, valamint maximális visszaesés (maximum drawdown, MDD) alapján elemezték. A szimuláció során az LSTM modell által generált vételi és eladási jelzéseket követték, kiegészítve ezeket fix stop-loss és take-profit szintekkel, ami lehetővé tette a kockázatkezelés szigorítását. A stratégia legjobb teljesítményét a Tesla (TSLA) részvény esetében tapasztalták, ahol az évesített hozam elérte a 41,26%-ot, miközben a Sharpe-mutató 1,79 volt, míg a maximális visszaesés mindössze -12,34%. A Microsoft (MSFT) részvényénél az évesített hozam 29,47%, a Sharpe-ráta 1,12, a maximális visszaesés pedig -10,51% volt. Ezzel szemben a buy and hold stratégia hozama ezekben az esetekben rendre 14,85%

és 12,21% körül alakult, jóval alacsonyabb Sharpe-mutatók mellett (TSLA: 0,58; MSFT: 0,44). A kutatás eredményei azt mutatják, hogy az LSTM-alapú döntési logika nemcsak a piaci trendek előrejelzésére alkalmas, hanem aktív kereskedési stratégiák szintjén is képes kimutathatóan jobb teljesítményt nyújtani. Továbbá az LSTM-modellek által generált stratégiák jellemzően kisebb maximális visszaeséssel és magasabb hozam/kockázati mutatókkal működtek, mint a klasszikus benchmark stratégia. A szerzők hangsúlyozzák, hogy az ilyen modellek különösen hatékonyak lehetnek közepes időtávokon, ahol az árfolyamsorokban rejlő időbeli mintázatok jól érvényesíthetők. A tanulmány így egyértelműen alátámasztja, hogy az LSTM-alapú árfolyam-előrejelzés nemcsak elméleti, hanem gyakorlati előnyöket is kínál a tőkepiaci kereskedésben. Shah et al. (2022) tanulmánya egy mélytanulási architektúrákon alapuló részvénypiaci kereskedési keretrendszert mutat be, amely a Nifty 50 index mozgásainak automatizált kereskedését célozza. A javasolt stratégia alapját egy halmazozott (stacked) CNN-LSTM modell képezi, amely 20 napos visszatekintési időszak alapján elemzi a piaci adatokat. Bár a fő cél az árak pontos előrejelzése, a tanulmány implicit módon egy kereskedési stratégiát is leír, amely ezen predikciókra épül. A rendszer a Nifty 50 index záróárának előrejelzése alapján generál vételi vagy eladási jelzéseket, optimalizálva a kereskedési döntéseket. A CNN-LSTM megközelítés hatalmas hozamnövekedést mutat a hagyományos „buy and hold” módszerhez képest, amely 10 év alatt 107%-os hozamot biztosított, míg a szerzők által alkalmazott stratégia 342%-os többlethozamot ért el. Az előrejelzési értékek számszerűsítése, amely modelljük célváltozója, segíthet a kereskedőknek a kereskedési beállítások azonosításában, különösen az opciós származtatott ügyletek esetében. Cheng et al. (2022) a kutatásukban egy idősor-modellt vizsgáltak, amely mélytanulást és integrált indikátorválasztási módszert alkalmaz a részvényárfolyamok előrejelzésére és a kereskedési stratégiák kialakítására. A javasolt keretrendszer tehát egy hibrid megközelítésre épül, mely a pénzügyi technikai indikátorok automatikus szelekcióját kombinálja a mélytanulási modellekkel. A kulcsfontosságú eleme a stratégiának, hogy a kiválasztott technikai indikátorok alapján generál vételi és eladási jelzéseket, melyek közvetlenül befolyásolják a kereskedési döntéseket. A modell teljesítményét Tajvan részvénypiaci adatain tesztelték, különös figyelmet fordítva a tényleges kereskedési profitok értékelésére. A kísérleti eredmények igazolták, hogy a javasolt modell jelentős kereskedési profitot képes elérni. Konkrétan, a modell 30 napos tesztidőszakban 4,5%-os bruttó hozamot realizált, szemben a "buy-and-hold" stratégia 0,5%-os veszteségével. A tanulmány hangsúlyozza a technikai indikátorok és a mélytanulás szinergikus alkalmazásának előnyeit a megbízhatóbb és profitábilisabb algoritmikus kereskedési stratégiák kialakításában.

A tanulmányok szempontjából a másik népszerű eszközosztályban a kriptovaluták számítanak. Ezek közül is bemutatok néhány empirikus eredményt az alábbiak szerint. Jing és Kang (2024) kutatásukban egy automatizált kriptovaluta kereskedési stratégiát mutatnak be, amely egy együttes

(ensemble) mély megerősítő tanulási (DRL) modellt alkalmaz, kiemelten a gyertyaalakzatok (candlestick images) vizuális információinak értelmezésével. A stratégia lényege, hogy a DRL módszer a többfelbontású gyertyaalakzat-képekből nyert időbeli és térbeli információk alapján tanulja meg a komplex piaci mintázatokat és ennek alapján hozza meg a vételi/eladási döntéseket. A modell teljesítményét különböző adatípusokon és stratégiákon keresztül értékelték egy 30-napos tesztidőszakon. A "Candlestick Images" (CI) adatokat használó DQN modell mutatta a legjobb teljesítményt a DRL alapú stratégiák közül, amely 26,12%-os hozamot ért el a tesztidőszakban. Ennek Sortino rátája 0,0344 volt, maximális visszaesése -2,10%. Ez a stratégia jelentősen felülmúlta a hagyományos "buy-and-hold" stratégiát, amely 18,54%-os hozamot és 0,02-es Sortino rátát produkált ugyanazon időszak alatt. A tanulmány hangsúlyozza, hogy az együttes DRL megközelítés, a gyertyaalakzatok átfogó vizuális információinak felhasználásával jobb megértést biztosít a piaci dinamikákról, ami a hagyományos módszereknél hatékonyabb és profitábilisabb kereskedési döntésekhez vezethet a volatilis kriptovaluta piacokon. Omole és Enke (2024) tanulmánya mélytanulási modelleket alkalmaz a Bitcoin árfolyamirányának előrejelzésére és empirikusan összehasonlítja az ezekre az előrejelzésekre épülő kereskedési stratégiák profitabilitását. A kutatás különböző mélytanulási modelleket (CNN-LSTM, LTSM, TCN) és az ARIMA (benchmark) modellt hasonlítja össze, on-chain adatok felhasználásával és jellemzőválasztási módszerek (Boruta, genetikai algoritmus, LightGBM) alkalmazásával. A kereskedési stratégia lényege, hogy a Bitcoin árfolyamirányának predikciója alapján generál vételi vagy eladási döntéseket. A szimulált kereskedési eredmények alapján a "Long and short" stratégia mutatta a legkiemelkedőbb teljesítményt, 6653,74%-os éves hozammal és 1,85-ös Sharpe-rátával. Ez jelentősen felülmúlta a "Long-only buy-and-sell" (437,24% hozam, 0,13 Sharpe-ráta) és a "Short-only buy-and-sell" (1084,16% hozam, 0,18 Sharpe-ráta) stratégiákat. A tanulmány hangsúlyozza továbbá, hogy a mélytanulási modellek és a gondos jellemzőválasztás kulcsfontosságú a kriptovaluta piac volatilis és komplex környezetében való sikeres és profitábilis navigáláshoz. Ghadiri és Hajizadeh (2025) tanulmánya egy fejlett, mesterséges intelligencián alapuló kereskedési rendszert mutat be, amely a kriptodevizák magas volatilitására reflektál. A szerzők kétlépcsős megközelítést alkalmaznak: először az XGBoost algoritmussal választják ki a leginformatívabb változókat (pl. piaci, technikai, makrogazdasági és blokklánc-adatok közül), majd ezekre építve egy mély tanulási modellt valósítanak meg, amely LSTM, BiLSTM és GRU rétegekkel generál vételi és eladási jelzéseket. A modellt Bitcoin és Ethereum adatokon tesztelték (2017-2023 közötti időszak) és az eredmények szerint a javasolt stratégia jelentősen túlteljesítette a buy-and-hold megközelítést. A Bitcoin esetében a GRU-XGB modell 24,85%-os évesített hozamot és 0,514-es Sharpe-mutatót ért el, míg a referencia buy-and-hold stratégia csupán -8,9%-os hozamot és 0,01-es Sharpe-értéket produkált. Az Ethereum esetében az LSTM-XGB modell

volt kiemelkedő a 90,26%-os évesített hozamával és 1,22-es Sharpe-mutatóval. A tanulmány emellett Wilcoxon-próbával statisztikailag is alátámasztja a modellek szignifikáns többlétejesítményét, különösen a GRU és BiLSTM architektúrák esetében. A szerzők hangsúlyozzák a blokklánc-változók jelentőségét és a mély megerősítéses tanulás gyakorlati előnyeit, ugyanakkor rámutatnak a túlilleszkedés, az adattelítettség és a hiperparaméter-optimalizálás kihívásaira is. Kang, Hong és Kim (2025) tanulmányukban a mélytanulás alapú árfolyampredikció és a technikai indikátorok kombinált alkalmazásával vizsgálták a kriptovaluta-kereskedési stratégiák hatékonyságát. A kutatás célja az volt, hogy az előrejelzési pontosságot kihasználva olyan kereskedési döntéstámogató rendszert hozzanak létre, amely képes javítani a hozam-kockázat arányt különböző kriptoeszközök (Bitcoin, Ethereum és Ripple) esetében. A szerzők tizenkét különböző deep learning architektúrát, köztük SegRNN, Transformer és TimesNet modelleket alkalmaztak, majd ezeket különféle technikai indikátorokkal (Bollinger Bands, RSI és MACD) kombinálták a kereskedési stratégiák szimulációjában. A backtesztelések négy eltérő időperióduson (30 perces, 1 órás, 4 órás, napi) zajlottak és a teljesítményértékelés során a hozam, a maximális visszaesés (Max Drawdown), valamint a Sharpe-mutató alapján hasonlították össze az eredményeket. A legjobb teljesítményt az ETH piacon elért stratégia nyújtotta, amely a TimesNet modellt Bollinger Bands indikátorral kombinálta. Az így kialakított stratégia hozama elérte a 3,19%-ot, miközben a maximális visszaesés -7,46%, a Sharpe-mutató pedig 3,56 volt, ami jelentősen meghaladta a buy-and-hold referenciaértékeket. A tanulmány eredményei azt mutatják, hogy bár a mélytanuló modellek önmagukban is pontos előrejelzéseket képesek produkálni, a technikai indikátorokkal történő kombinálásuk tovább növeli a kereskedési stratégiák hatékonyságát. A kutatás különösen kiemeli a közepes időtávú (4 órás) előrejelzések gyakorlati előnyeit, valamint a deep learning modellek és technikai indikátorok szinergikus alkalmazásának lehetőségeit a kriptovaluta piacokon. Viéitez et al. (2024) kutatásukban az Ethereum árfolyamának előrejelzésére és a kapcsolódó befektetési stratégiák teljesítményének értékelésére fókuszálnak, különösen a gépi tanulási modellek gyakorlati kereskedési hasznosíthatóságára. A szerzők különböző modelleket, többek között LSTM, GRU és SVM alkalmaztak egy mérsékelt volatilis és egy erősen ingadozó piaci időszakra vonatkozóan. A modellekre épülő kereskedési stratégiákat kumulatív hozam és Sharpe-mutató alapján értékelték és összehasonlították a passzív „buy-and-hold” stratégiával. A legeredményesebb stratégia a második, volatilisabb időszakban született, amelyet az LSTM modellre épített aktív kereskedési megközelítés produkált. A tesztelés során kiemelkedően alacsony veszteségaránnyal működött, miközben az évesített kumulatív hozam többszöröse volt a referencia buy-and-hold stratégiának. Az első periódusban a GRU modell Pearson-féle jellemzőválasztással kombinálva 373,4%-os kumulatív hozamot ért el, míg ugyanebben az időszakban a buy-and-hold stratégia hozama

mindössze 91,9% volt. Az eredmények azt is mutatják, hogy a legjobb aktív stratégia Sharpe-mutatója (1,36) lényegesen meghaladta a benchmark referenciaértékét (0,52), ami egyértelműen jelzi a kockázati hozamarány jelentős javulását. A tanulmány külön érdeme, hogy a gépi tanulási modellek nemcsak az árfolyam irányát voltak képesek sikeresen előre jelezni, hanem olyan megbízható kereskedési stratégiákat is generáltak, amelyek szignifikánsan felülteljesítették a passzív befektetési megközelítéseket. Az eredmények különösen meggyőzőek a nagy volatilitású időszakokban, ahol a hagyományos buy-and-hold gyakran alacsonyabb hozamot és magasabb kockázatot eredményezett. Mindez alátámasztja, hogy a megfelelően validált gépi tanulási modellek különösen az LSTM és GRU hálózatok, képesek a kriptopiacok előrejelzésének és kereskedési stratégiáinak megbízható alapjául szolgálni. A legtöbb tanulmány hangsúlyozza, hogy a hozamok bruttóként jelennek meg, azaz a különféle adók, tranzakciós és egyéb költségek figyelembe vétele nélkül történik a vizsgálat. A 2. táblázat a kereskedési stratégiákkal kapcsolatos szakirodalmak Sharpe-mutatóit tartalmazza a buy-and-hold és az aktív stratégiák vonatkozásában.

2. táblázat: A Sharpe-mutatók alakulását bemutató összefoglaló táblázat

Szerző	Instrumentum	Sharpe (buy-and-hold)	Sharpe (aktív stratégiák)
Pourahmadi et al. (2024)	S&P 500 index	0,057	0,444
Ju et al. (2025)	Tesla, Microsoft	0,580	1,790
Omole és Enke (2024)	Bitcoin	0,130	1,850
Ghadiri és Hajizadeh (2025)	Bitcoin, Ethereum	0,010	0,514
Viéitez et al. (2024)	Ethereum	0,520	1,360

Forrás: saját szerkesztés

2.9. Szakirodalmi áttekintés a volatilitás és az előrejelző modellek teljesítményének kapcsolatáról

A pénzügyi idősorok sajátossága, hogy gyakran nem stacionáriusak, ami azt jelenti, hogy statisztikai tulajdonságaik, különösen a volatilitásuk, idővel változnak. Ez a dinamikus viselkedés jellemzően alacsony volatilitású és magas volatilitású, stabil és turbulens periódusok váltakozásával jár együtt, ami komoly kihívást jelent a hagyományos, statikus előrejelző modellek számára. Ezek a módszerek nem képesek kellőképpen alkalmazkodni a hirtelen változásokhoz, ami ronthatja predikciós pontosságukat és robusztusságukat. Az elmúlt évtizedben azonban a gépi tanulási (ML) és mélytanulási (DL) módszerek forradalmasították az idősor-előrejelzést, új lehetőségeket nyitva meg a volatilitás explicit figyelembevételére a modellezés során. Ez a szakirodalmi áttekintés azokat az gépi és mély tanulás (ML/DL) alapú megközelítéseket mutatja be, amelyek nem feltétlenül a volatilitás előrejelzésére koncentrálnak, hanem arra, hogy az előrejelző rendszerek képesek legyenek adaptívan kezelni a volatilis környezetet, ezáltal stabilabb és pontosabb predikciókat szolgáltatni a különböző piaci rezsimekben. Mindez pedig hozzájárul a

modellek volatilitás-érzékenységének kezeléséhez, ami nagyobb becslési pontosságot eredményez.

2.9.1. Rezsimváltó mechanizmusok alkalmazása, avagy adaptáció a változó piaci körülményekhez

A piaci viselkedésben megfigyelhető, eltérő volatilitású „rezsimek” felismerése és kezelése alapvető fontosságú a robusztus előrejelzés szempontjából. A rezsimváltó mechanizmusok integrálása az előrejelző modellekbe lehetővé teszi, hogy a rendszer dinamikusan alkalmazkodjon a piaci állapotok változásaihoz. Ezáltal a modell predikciója mindig az aktuális volatilitási környezetre optimalizálható. A rejtett Markov-váltó (Hidden Markov Model, HMM) modellek széles körben alkalmazott statisztikai keretrendszerek a rezsimváltás modellezésére, és gyakran képezik a gépi tanulási alapú adaptív rendszerek magját. Zhang és Zhang (2022) tanulmányukban egy Markov-rezsimváltós diffúziós modellt alkalmaznak barrier opciók árának meghatározására, különös tekintettel a gazdasági környezetben bekövetkező strukturális változások hatására. A klasszikus Black–Scholes kerethez képest a javasolt modell lehetővé teszi a volatilitás és a kockázatmentes kamatláb időbeli változását, amelyeket Markov-lánc vezérel. A modell validálásához kiterjedt numerikus kísérleteket végeztek, valamint illesztették az S&P 500 index adataihoz, ahol összehasonlították a klasszikus Black–Scholes árakkal. Az empirikus vizsgálatok során is bebizonyosodott, hogy a Markov-rezsimváltós modell jobban megragadja a volatilitás-klaszterezés és a vastag eloszlási szélű hozamok jellemzőit, így az opciós árazás pontossága javul. Carpenteyro és munkatársai (2021) tanulmányukban a nemesfémek (arany, ezüst, platina) napi hozamait modellezik egy komplex sztochasztikus struktúrával. Az alkalmazott Markov-rezsimmodell lehetővé teszi, hogy a piaci állapotok függvényében változzanak a főbb paraméterek. Ez a modell képes kezelni a volatilitás-klaszterezést, a nem szimmetrikus eloszlásokat és a strukturális töréseket is. Az eredmények szerint az arany stabilabb rezsimdinamikát mutat, míg az ezüst esetében gyakoriak a nagy volatilitású rezsimváltások. A Markov-struktúra jól visszaadja a hozamsorok időben változó jellemzőit és nagyobb rugalmasságot biztosít, mint az időben állandó paraméterű modellek. Shi (2023) a hosszútávú memória algoritmusok és a rezsimváltás közötti ambivalenciát vizsgálja a sztochasztikus volatilitás (SV) modellezésén belül. A szerző bemutatja, hogy a Markov-rezsimváltással támogatott modell a szimulációk alapján képes megkülönböztetni a valódi hosszútávú memória és a rezsimváltás okozta torzulásokat, valamint konzisztens becslést nyújt a hosszú memória paraméterére. Az S&P 500 index 2007–2019 közötti napi hozamain végzett empirikus vizsgálat igazolja a modell gyakorlati előnyeit. Többek között kimutatható, hogy a jelentős hosszútávú memória kizárólag a magas volatilitású állapotban van jelen, míg az alacsony volatilitású

periódusok rövidtávú memóriát mutatnak. A tanulmány hangsúlyozza, hogy a volatilitási állapotok rezsimmfüggő kezelése fontos szerepet játszhat a kockázatmenedzsment stratégiák kidolgozásában.

A mélytanulás területén a rezsimkapcsolóval ellátott DNN-hibrid modellek ígéretes eredményeket mutattak. Ezek a modellek a neurális hálózatok szekvenciális adatfeldolgozási és nemlineáris mintázattanulási képességét ötvözik egy rezsim-érzékeny modullal. Avinash et al. (2024) tanulmányának célja a romlandó zöldségfélék (paradicsom, hagyma és burgonya) árának pontos előrejelzése, különös tekintettel a piaci árak nemlineáris és nemállandó természetére. A szerzők Hidden Markov Modellek (HMM) és mélytanulási (DL) modellek (MLP, RNN, GRU és LSTM) hibridizációját javasolják az árak előrejelzési pontosságának növelésére. A HMM rejtett állapotainak alkalmazása jellemzők kinyerésére szolgál, amelyeket ezután a DL modellek bemeneti változóiként használnak. A kutatás során egy valós adatbázis, az Azadpur Mandi piacon (Delhi) rögzített heti árakat használták 2006–2023 között. Az eredmények szerint a HMM-mel kombinált DL modellek szignifikánsan javítják az előrejelzési teljesítményt az alap DL modellekhez képest, különösen turbulens piaci körülmények között. A HM-RNN és HM-LSTM modellek kiemelkedtek, különösen alacsonyabb hibaértékek, amit a Diebold-Mariano tesztek is megerősítettek. A tanulmány hangsúlyozza a hibrid modellek interpretálhatóságát, robusztusságát és alkalmazhatóságát más nemlineáris, volatilis idősorok előrejelzésében is. Sivakumar (2025) tanulmánya egy új, HMM (Hidden Markov Model) és LSTM (Long Short-Term Memory) hálózatokat ötvöző modellt mutat be az infláció előrejelzésére. A szerző célja a gazdasági idősort jellemző rejtett állapotok és azok statisztikai jellemzőinek (átlagok) integrálása az LSTM bemeneti változói közé, ezzel javítva a modell prediktív teljesítményét és értelmezhetőségét. Az adatgyűjtést és előfeldolgozást követően a HMM segítségével azonosította a gazdasági ciklusokat reprezentáló rejtett állapotokat, majd ezeket felhasználta az LSTM modellek tanításához. Az eredmények azt mutatják, hogy a HMM-ből származó jellemzők jelentősen javítják az előrejelzések pontosságát, különösen a rövid távú (1 éves) előrejelzések esetén. A modell értelmezhetőségét az integrált gradiens módszerrel vizsgálták, amely betekintést nyújtott a legfontosabb gazdasági tényezők hatásába. A hosszabb távú (2,5 éves) előrejelzések esetén a modell teljesítménye csökkent, de a volatilitás mérséklődött. Összességében a HMM-LSTM fúziós modell ígéretes megközelítést kínál az inflációs előrejelzések pontosságának és értelmezhetőségének javítására. Aydogan-Kilic és Selcuk-Kestel (2023) kutatásukban egy pénzügyi idősorokra adaptált hibrid modellt mutat be, amely a Recurrent Neural Network (RNN) és a Hidden Markov Model (HMM) módszereit ötvözi. A cél a HMM paraméterérzékenységének csökkentése és a globális maximum elérése az RNN tanulási képességeinek kihasználásával. A modell újdonsága, hogy a veszteségfüggvényt nem a maximális valószínűsége, hanem közvetlenül az árfolyamok eltérésére definiálja, így a predikciók közelebb kerülnek a valós értékekhez. A szerzők egy-, két- és többváltozós esetekben is vizsgálták

a modell teljesítményét az S&P 500, Nasdaq és EUR/USD napi adatokon. Az eredmények szerint a hibrid modell szignifikánsan jobb előrejelzési pontosságot nyújt, különösen az erősen korrelált változók esetén. A modellt összehasonlították klasszikus HMM, RNN, valamint LSTM és GRU modellekkel is és a legtöbb esetben a hibrid megközelítés bizonyult a leghatékonyabbnak. A tanulmány kiemeli a HMM interpretálhatóságát és az RNN tanulási képességeit, valamint bemutatja, hogyan lehet ezeket kombinálni a pénzügyi rendszerek állapotainak pontosabb feltérképezésére. Mari és Mari (2023) az energiahordozók árának előrejelzésével foglalkoztak, melyhez olyan modellt fejlesztettek, ami képes kezelni a piaci rezsimok váltakozását mindezt kombinálva a gépi tanulás lehetőségeivel. A szerzők által kidolgozott hibrid módszer az alaprezsimeket egy átlaghoz visszatérő diffúziós folyamatként veszi figyelembe, míg a második rezsim működését egy mély neurális hálózat (DNN) predikciói vezérlik. Az áttörést az jelenti, hogy a rezsimok közti váltás nem egy rejtett Markov-láncon alapul, hanem a DNN predikciós valószínűsége határozza meg a dinamikát. A modellben több LSTM-rétegből álló RNN-struktúrát alkalmaznak, amit egy konvolúciós és egy pooling réteg előz meg, ezáltal lehetővé téve a szekvenciális, nemlineáris összefüggések észlelését. Az empirikus vizsgálat három energiahordozóra (villamos energia, földgáz, nyersolaj) terjedt ki és kimutatta, hogy a javasolt modell jelentős pontossággal képes visszaadni a loghozamok négy fő momentumát (átlag, szórás, ferdeség, csúcsosság), megelőzve két klasszikus rezsimváltó modellt (egy diffúziós és egy ugrás-diffúziós Markov-modellt). A modell további előnye, hogy kevesebb paramétert igényel, miközben flexibilitást nyújt a turbulens időszakok kezelésére. A DNN-alapú rezsimváltás lehetővé teszi a prediktív struktúrák kihasználását a volatilitás időfüggő adaptálásában. A szerzők hangsúlyozzák a módszer gyakorlati jelentőségét kockázatkezelés és fedezeti stratégiák szempontjából. A szerzőpáros (Mari és Mari, 2025) későbbi tanulmányukban egy új módszertant mutat be árupiaci (konkrétan földgáz) árfolyamok sztochasztikus modellezésére, amely mély neurális hálózatokra (DNN) épül. A szerzők célja az volt, hogy a piaci ármozgások legfontosabb tulajdonságait felhasználják (átlaghoz való visszatérés, a hirtelen fellépő volatilitás és az erős nemlineáris hatások) és egy adatvezérelt DNN-modell révén modellezzék, amely nem igényel bonyolult paraméterbecslést. A DNN hibrid architektúrája konvolúciós rétegeket, LSTM rétegeket és egy Softmax kimeneti réteget használ, lehetővé téve a feltételes valószínűségi eloszlások becslését, amelyekből Monte Carlo módszerrel teljes árfolyampályák szimulálhatók. A modell jól megragadta a természetes gáz árfolyamának átlaghoz visszatérő és volatilis dinamikáját. A tanulmány különösen kiemeli, hogy a Softmax-alapú valószínűségi becslés révén a DNN nem csupán pontbecsléseket nyújt, hanem teljes eloszlásokat is képes reprezentálni. A DNN megközelítés további előnye, hogy hatékonyan kezelhető nemállandó (nonstationary) piaci körülmények között is, mivel könnyen újratanítható új adatokkal. Összességében a tanulmány egy

paradigmaváltó, adatalapú irányt mutat a pénzügyi árfolyammodellezésben, különösen árupiaci idősorok esetén.

2.9.2. A releváns volatilitási információk fókuszált figyelembevétele az előrejelző modellekben

Az figyelem (attention) mechanizmusok a mélytanulás egyik legjelentősebb innovációját képviselik, forradalmasítva a szekvenciális adatok feldolgozását. Ezek a mechanizmusok lehetővé teszik a modellek számára, hogy szelektíven fókuszáljanak a bemeneti idősorok legrelevánsabb részeire az előrejelzés során. Ez a képesség különösen hasznos a volatilis pénzügyi idősorok esetén, ahol bizonyos múltbeli események vagy periódusok (hirtelen piaci sokkok) nagyobb jelentőséggel bírhatnak a jövőbeli előrejelzés szempontjából, és a modellnek ezt figyelembe kell vennie.

Ouyang et al. (2021) tanulmányukban egy figyelem alapú LSTM modellt fejlesztettek a kínai pénzügyi piac szisztematikus kockázatának korai előrejelzésére. A szerzők egy többdimenziós, nemlineáris megközelítést javasolnak, amely a hagyományos pénzügyi kockázati mutatók és volatilitás mellett figyelembe veszi az online közösségi platformokon megjelenő hálózati véleményindexet is. Az empirikus vizsgálat során a kutatók összehasonlították az attention-alapú LSTM modellek teljesítményét különféle benchmark modellekkel, mint az ARIMA, SVR és hagyományos BPNN. Az eredmények egyértelműen azt mutatták, hogy az Attention-LSTM modell különösen a hálózati véleményindex bevonásával jelentős javulást mutatott a predikciós teljesítményben. A modell sikerének kulcsa abban rejlik, hogy az figyelem mechanizmus révén a rendszer képes volt szelektíven fókuszálni a predikció szempontjából leginkább releváns jellemzőkre, legyenek azok pénzügyi mutatók vagy szöveges információk. Ez különösen fontosnak bizonyult a piac volatilitását és instabilitását reprezentáló változók esetében. A figyelemmechanizmus hatékonyan segítette a modell alkalmazkodását a dinamikusan változó gazdasági környezethez és támogatta a robusztus, megbízható előrejelzések készítését. Összességében a tanulmány hozzájárul a pénzügyi kockázatmodellezés azáltal, hogy a volatilitást nem csupán kiegészítő szempontként kezeli, hanem a prediktív teljesítmény egyik meghatározó elemeként. Zhang és szerzőtársai (2023) tanulmányukban egy összetett, figyelemalapú mélytanulási modellt javasolnak a részvényárfolyamok előrejelzésére, amely a konvolúciós neurális hálózat (CNN), a kétirányú hosszú-rövid távú memóriahálózat (BiLSTM), valamint az attention mechanizmus integrációján alapul. A modell célja a pénzügyi idősorok jellemzőinek hatékonyabb megragadása, különös tekintettel a nemlineáris dinamikára, a hosszú távú függőségekre és a fontos időpontok automatikus azonosítására. A CNN komponens lokális mintázatokat detektál, míg a BiLSTM képes a visszamenőleges és előreutató időbeli összefüggések feltárására. Az attention réteg ezekre az idősoros rejtett állapotokra alkalmaz

súlyozást, kiemelve azokat az időpillanatokat, amelyek az előrejelzés szempontjából legnagyobb jelentőséggel bírnak. A tanulmány szerint az attention mechanizmus a BiLSTM kimenetein működik, és a relevancia súlyokat egy tanulható mátrix segítségével generálja, amely a rejtett állapotok belső jellemzőin (nem külső változókon) alapul. Az empirikus validálás során a modellt a CSI 300 index, valamint további három kínai és nyolc nemzetközi részvényindex (pl. AEX, FTSE, HSI) adatai alapján tesztelték. A CNN-BiLSTM-Attention modell minden esetben felülteljesítette a klasszikus LSTM, CNN-LSTM és CNN-LSTM-Attention architektúrákat. Például a CSI 300 index esetében a modell MAPE értéke 1,023% volt, szemben az LSTM modell 1,877%-os értékével, míg az RMSE 64,85-re csökkent, és az R^2 érték 0,985-re javult. A modell robusztusságát az is alátámasztja, hogy különféle piaci struktúrák mellett (fejlett és fejlődő piacok) is konzisztens teljesítményt mutatott. A szerzők kiemelik, hogy az attention mechanizmus jelentős mértékben javítja az előrejelzés pontosságát azáltal, hogy dinamikusan azonosítja és súlyozza a döntéshozatalhoz legfontosabb időpillanatokat. A tanulmány hozzájárulása abban áll, hogy egy általánosan alkalmazható, mégis adaptív architektúrát kínál, amely különösen alkalmas pénzügyi idősorok komplex, rezsimváltásokkal és rejtett mintázatokkal jellemezhető dinamikájának modellezésére. Yu, Feng és Liu (2025) tanulmányukban egy új, adaptív Sharpe-ráta-alapú Temporal Fusion Transformer modellt (AS-TFT) mutatnak be, amely a pénzügyi idősortípusú előrejelzések során nem csupán a predikciós pontosságot, hanem a kockázattal súlyozott megtérülést is figyelembe veszi. A szerzők kiindulópontja az a felismerés, hogy a hagyományos mély tanulási modellek ugyan képesek komplex, hosszú távú időbeli összefüggések tanulására, ám jellemzően kizárólag hibaminimalizáló (pl. MSE) veszteségfüggvények alapján optimalizálnak, figyelmen kívül hagyva a pénzügyi döntéshozatalhoz kulcsfontosságú kockázathozam arányokat. Az AS-TFT modell különlegessége, hogy a Sharpe-rátát nem csupán értékelési mutatóként, hanem tanítási célfüggvényként is integrálja. Ez azt jelenti, hogy a hálózat előrejelzéseit nem csupán a tényleges ármozgásokhoz való illeszkedés, hanem a portfólió teljesítményéhez való hozzájárulás alapján súlyozza, figyelembe véve a volatilitást, mint implicit kockázati tényezőt. A modell figyelemmechanizmusa a Temporal Fusion Transformer architektúrán alapul, amely többszörös önfigyelő (multi-head self-attention) rétegeket alkalmaz az időbeli összefüggések kiemelésére. A modell tanítása során reinforcement learning elemeket is alkalmaztak, amelyek lehetővé tették a tanulás során a Sharpe-ráta mint jutalomfüggvény folyamatos adaptálását a piaci környezethez. Az AS-TFT teljesítményét többféle eszközosztályon részvényindexeken, kriptovalutákon és árupiaci termékeken is validálták. Az eredmények alapján az AS-TFT nemcsak alacsonyabb RMSE és MAPE értékeket ért el, hanem jelentősen magasabb Sharpe-rátát biztosított a benchmark modellekhez (ARIMA, LSTM, standard Transformer) képest. Ezen túlmenően a modell a Sortino-mutató tekintetében is javulást mutatott, különösen a volatilis

időszakokban. Összességében a tanulmány hozzájárulása abban áll, hogy a pénzügyi mélytanulási modellezés során nemcsak a prediktív pontosságot, hanem a kockázatérzékeny optimalizálást is előtérbe helyezi, egy olyan architektúrával, amely hatékonyan ötvözi a transformer típusú figyelemmechanizmust, a portfóliómenedzsment céljait és a megerősítéses tanulás előnyeit. Az AS-TFT ezzel nemcsak tudományos újdonságot, hanem gyakorlati alkalmazhatóságot is kínál kockázatérzékeny befektetési döntések támogatásához. Li és Xu (2024) tanulmánya a részvényárfolyam-előrejelzés pontosságának növelését célozza a generatív adverzális hálózatok (GAN) és transformer-alapú figyelemmechanizmusok ötvözésével. A modell az Apple hatéves részvénytári adataira épül és kiegészül különféle technikai indikátorokkal (pl. mozgóátlagok, Bollinger-sávok, Fourier-komponensek), piaci hangulati mutatókkal (FinBERT elemzés alapján), valamint volatilitás- és makrogazdasági indikátorokkal (pl. VIX index, állampapírhozamok). A GAN komponens a szintetikus adatok generálásával segíti a robusztus tanulást, míg a transformer-alapú figyelem lehetővé teszi, hogy a modell fókuszáljon a legrelevánsabb múltbeli mintázatokra. A pénzügyi értékelés során a modell által előre jelzett befektetési döntések összehasonlításra kerülnek a valós piaci hozamokkal. Az Apple részvényekre alkalmazott stratégia alapján a modell átlagos előrejelzett ROI-ja 30,27%, míg a tényleges ROI 36,88% volt. A Sharpe-mutató közel azonos lett, azonban a Treynor-mutató és a Jensen-alfa esetén már nagyobb eltérés mutatkozott. Ez arra utal, hogy bár a modell jól képes megragadni a piaci trendeket, bizonyos kockázati jellemzőket, mint például a szisztematikus kockázat alulbecsülhet. A modell teljesítményét az Amazon, Microsoft és Google részvények esetében is tesztelték és a standardizált RMSE-értékek alapján azoknál is versenyképes előrejelzési teljesítményt mutatott. Az eredmények szerint a GAN és figyelemmechanizmus kombinációja ígéretes eszköz lehet pénzügyi előrejelzések és kereskedési stratégiák támogatásában. Luo et al. (2024) tanulmányának célja a részvények közötti rövid távú korrelációs viszonyok előrejelzése mélytanulási architektúrák segítségével, különös tekintettel a nemlineáris és időben változó összefüggések megragadására. A szerzők a CLATT (CNN-BiLSTM-Attention) nevű hibrid modellt fejlesztették ki, amely ötvözi a konvolúciós hálózatok lokális mintázatfelismerő képességeit, a BiLSTM idősorfüggőségeket feltáró struktúráját, valamint az figyelem mechanizmus szelektív fókuszálási tulajdonságait. Az előrejelzések pontosságát az S&P500 index adatain tesztelték és összehasonlították több alapmodellel, köztük LSTM, BiLSTM és CNN-only konfigurációkkal. Az eredmények alapján a CLATT modell minden összehasonlításban szignifikánsan jobb teljesítményt nyújtott, különösen a prediktív RMSE és MAE mutatók terén. Kiemelendő, hogy a modell kifejezetten jól teljesített magas volatilitású periódusokban is, ahol más algoritmusok gyakran túlilleszkednek vagy elveszítik prediktív erejüket. A tanulmány hangsúlyozza, hogy az figyelem mechanizmus segít azonosítani azokat az időszakokat a múltban, amelyek különös jelentőséggel bírnak a jövőbeli

korrelációs struktúrák meghatározásában, ezáltal a volatilis, strukturálisan váltakozó piaci környezethez való adaptációt is elősegíti. A modell érzékenysége a piaci sokkokra és átmeneti rezsimekre különösen fontossá válik pénzügyi válsághelyzetek vagy hirtelen piaci irányváltások esetén. A szerzők szerint ez a megközelítés nemcsak az előrejelzési teljesítményt javítja, hanem hozzájárulhat a kockázatalapú döntéstámogatás pontosságához portfólióoptimalizálás és eszközallokáció terén is. Összességében a CLATT architektúra nemcsak a mély tanulási modellek predikciós potenciálját demonstrálja, hanem rámutat arra is, hogy a volatilitás adaptív kezelésére alkalmas komponensek kulcsszerepet játszhatnak a pénzügyi előrejelző rendszerek fejlődésében. A tanulmány így fontos hozzájárulást jelent a volatilitásérzékeny mesterséges intelligencia-alapú előrejelzési kutatások terén.

2.10. A vizsgált időszak (2016–2022) globális pénzügyi és gazdaságpolitikai, sajátosságai, valamint ezek hatása a pénzügyi piacokra

A pénzügyi piacok előrejelzésére vonatkozó gépi tanulási modellek elemzése során fontos figyelembe venni a vizsgált időszakok globális pénzügyi és gazdaságpolitikai környezetét, mivel ezen tényezők alapvetően befolyásolják a piaci volatilitást és a különböző pénzügyi eszközök árainak alakulását. A következőkben az általam vizsgált három időszak meghatározó sajátosságait és azok hatásait mutatom be a globális gazdasági helyzetre és a pénzügyi piacokra vonatkozóan, különös tekintettel a részvények, kriptovaluták, árupiaci termékek és devizapárok esetében.

Nyugalmi időszak (2016. január 1. – 2018. június 30.)

Az időszak első fele a globális gazdaság lassú, de stabil növekedését hozta, amely a 2008-as pénzügyi válság utáni helyreállításhoz kapcsolódott. Az alacsony kamatlábak és a központi bankok által végrehajtott mennyiségi lazításhoz köthető (quantitative easing - QE) politikák dominálták a fejlettebb gazdaságokat, különösen az Egyesült Államokat és az Eurozónát (Caldentey, 2017). A pénzügyi piacok számára az ilyen politikák alacsony volatilitást eredményeztek, különösen a részvénypiacokon, bár egyes iparágak, mint az energia- és bányászati szektorok, nagyobb áringadozásokkal szembesültek (Chen et al., 2024). A Brexit népszavazás 2016-ban váratlan politikai és gazdasági bizonytalanságot okozott, különösen az euró- és angol font piacon, ami további volatilitást generált (Belke et al., 2018; Hudson et al., 2020). A kriptovaluták piacán, különösen a Bitcoin esetében, 2017 végén egy hatalmas spekulációs "buborék" alakult ki, amely a digitális eszközök piaci volatilitásának hirtelen növekedését eredményezte (White et al., 2020; Shilov és Zubarev, 2021). A kriptovaluták szélsőséges viselkedésétől eltekintve ezen időszak számít az elemzésemben a nyugalmi periódusnak, mivel nem volt olyan globális esemény, amely

radikális változást eredményezett volna a hagyományos pénzügyi termékek árfolyamainak alakulásában.

Covid19 időszak (2018. január 1. – 2020. június 30.)

Ez az időszak a USA–Kína kereskedelmi háború és annak következményei miatt volt különösen fontos. A kereskedelmi feszültségek hatására a globális kereskedelem és a gazdasági aktivitás visszaesett, ami megnövelte a piaci volatilitást és hatással volt a részvénytőzsdák és a devizapiacok árait is. A központi bankok, különösen az Európai Központi Bank (ECB) és a Federal Reserve (Fed), továbbra is alacsony kamatlábakkal támogatták a gazdaságot, miközben az inflációs nyomás nem volt jelentős (Bajra et al., 2025)). A pénzügyi piacok számára ez a szakasz fokozott bizonytalanságot és ingadozást eredményezett, különösen a részvény- és devizapiacokon. A Covid19 világjárvány előkészületei és terjedése 2020 elején globális gazdasági válságot indítottak el. A világ számos országában recessziók alakultak ki, míg a pénzügyi piacokon óriási volatilitás-növekedés volt tapasztalható. Az árupiaci termékek, mint az olaj árcsökkenést mutattak, míg az arany, mint menedékeszköz jelentős áremelkedésen ment keresztül (Yiming et al., 2024). A kriptovaluták piaca szintén először visszaesett a járvány hatására, de később, a fiskális és monetáris stimulusok hatására, erőteljes emelkedésbe kezdett (Echarte Fernández et al., 2021).

Orosz-ukrán konfliktus (2020. január 1. – 2022. június 30.)

A Covid19 világjárvány következményei dominálták a globális gazdasági helyzetet ebben az időszakban, amely az egyes piacokon rendkívüli változásokat eredményezett. A központi bankok agresszív fiskális és monetáris stimulusokat alkalmaztak a gazdaságok fenntartása érdekében, miközben a globális ellátási láncok megbomlottak, és számos iparág szenvedett az üzemzavarok következményeitől (Karanasos et al., 2022). A recessziók és a gazdasági zűrzavarok eredményeként a piaci volatilitás növekedett, különösen az árupiaci termékek és az energiapiacok területén. A devizapiacokon az amerikai dollár erősödése figyelhető meg a Fed politikájának következményeként, míg a fejlődő országok devizái, mint a török líra, gyengültek a gazdasági válság hatására (Zhu et al., 2025). A kriptovaluták piaca ebben az időszakban rekordmagasságokba emelkedett, különösen a Bitcoin és más digitális eszközök. A DeFi (decentralizált pénzügyek) elterjedése és a NFT piacok robbanása különösen fontos jelenségek voltak 2021-ben. A 2022 februári orosz-ukrán háború kitörése azonban drámai hatással volt a globális gazdaságra és pénzügyi piacokra. Az invázió hatására az energiapiacokon különösen nagy árfolyamingadozások voltak tapasztalhatók, mivel Oroszország kulcsfontosságú szereplője az olaj- és földgázpiacoknak. Az európai energiaválság gyors elmélyülése, valamint a kereskedelmi és pénzügyi szankciók miatt az energiaárak, különösen az olaj és a földgáz árfolyama, jelentősen megnövekedtek (Henderson,

2024). Az ilyen típusú geopolitikai kockázatok különösen az árupiaci előrejelzések teljesítményét befolyásolják, mivel az energiahordozók ára a globális gazdaság kulcseleme. A háború által előidézett gazdasági bizonytalanság az euró-dollár és más devizák árfolyamát is jelentősen befolyásolta, hiszen a piaci reakciók erősen reagáltak a szankciókra és a katonai konfliktusok hatásaira. Az orosz rubel gyors leértékelődése, valamint az euró és a dollár közötti ingadozások különösen kiemelkedtek. Ezen túlmenően, az orosz gazdaságra kivetett szankciók és a globális ellátási láncok továbbra is sérülékenyebbé tették a piaci infrastruktúrát. A kriptó- és digitális eszközök piacain szintén jelentős árcsökkenés volt megfigyelhető, különösen 2022 első felében, amikor a piaci bizonytalanságok és a globális inflációs nyomás egyre erősebben hatottak a digitális eszközök piacaira. A háború, valamint a központi bankok szigorúbb monetáris politikái hozzájárultak a kriptovaluták piaci volatilitásának növekedéséhez, különösen a Bitcoin és az Ethereum árfolyamaiban (Harb et al., 2024).

3. CÉLKITŰZÉSEK

A mesterséges intelligencia terjedését mi sem jelzi jobban, hogy a különféle tanuló algoritmusok 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 vélem, hogy elkerülhetetlen ezen 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 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 predikcióval foglalkozó szakértőknek a modellfejlesztések során alapvetően számos kihívással kell szembenéznük. A komplexitás, a zajos információk, a fejlődési sajátosságok és a nem lineáris kapcsolatok problémakörei többek között a tőzsde és a pénzügyi piacok 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, a kereskedőknek és a vállalati kockázatkezelésben az optimális döntések meghozatalához. 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 különféle stratégiák optimalizálása érdekében.

A kockázatkezelés fontossága különösen felértékelődik a magas volatilitású időszakban, mint pl. a 2008-as világválság, a Covid19 vagy az orosz–ukrán háború miatti tőzsdei összeomlás. Az inflációs környezet kiszámíthatatlanság további igényt támaszt a minél hatékonyabb eszközök használatára. Napjainkban a legmodernebb kockázatkezelési technikák túlmutatnak az hagyományos diverzifikáción és egyre inkább előtérbe kerülnek a mesterséges intelligencia alapú megoldások, amelyek a hétköznapijaink szerves részévé válnak. A kereskedési stratégiák esetében az árfolyamelőrejelző modellek kulcsfontosságú árfolyamszinteket képesek meghatározni, amelyek felhasználhatók a fundamentális és a technikai elemzés során, illetve a kockázatkezelés és portfóliómenedzsment területén egyaránt. A kutatásom legfőbb célja a gépi tanulási

modellekkel történő prediktív modellezés sajátosságainak feltérképezése. A részletes célkitűzéseket és hipotéziseket a továbbiakban ismertetem.

C1: A kutatásom első célkitűzése annak meghatározása, hogy a különböző neurális mély tanulási modellek milyen mértékben általánosíthatóak, azaz képesek-e különböző válsághelyzetekben is kimagasló prediktív teljesítmény elérésére.

Ebből kifolyólag három különböző időszakot elemzek, amelyben a 2018-as év jelenti a nyugalmi, míg a Covid19 (2020) és az orosz-ukrán konfliktusa kirobbanása (2022) a válsággal sújtott periódust.

K1: Milyen kapcsolat mutatható ki a pénzügyi eszközök volatilitása és az árfolyamelőrejelzési modellek prediktív teljesítménye között?

K2: Milyen előrejelzési torzulásokat okoznak a válságidőszakokban megfigyelhető szélsőséges árfolyammozgások és hogyan reagálnak erre különböző típusú algoritmusok?

K3: Milyen szerepet játszik a hibrid modellek architektúrája a prediktív teljesítmény változásában volatilis piaci környezetben?

A modellezés során kitérek arra is, hogy a vizsgált termékkategóriák közül melyik az, ami a legstabilabb és melyik az, amely a legnagyobb kihívást jelenti a prediktív algoritmusok számára. Jelentős eltérések tapasztalhatók a termékspecifikumok között ugyanis az elemzésben helyet kapnak a tradicionális és nagy múltra visszatekintő részvénypiacok, valamint a gazdasági mércével szinte még gyerekcipőben járó, de annál volatilisabb kriptovaluták. Árupiaci termékek is szerepet kapnak a vizsgálatban, amelyek árfolyamának alakulását rengeteg külső hatás befolyásolja, illetve a devizapiacokról sem szabad megfeledkezni, amely szintén különleges tulajdonságokkal rendelkezik, hiszen az árfolyamokat számos, egymással összefüggő tényező határozza meg, mint például a kamatkülönbségek, az infláció, a politikai stabilitás és a kereskedelmi kapcsolatok. A devizapárok közötti korrelációk is jelentős hatással lehetnek az előrejelzések pontosságára. A részvényindexek hosszabb távon követhetőbb trendeket mutatnak, míg a kriptovaluták és egyes árucikkek árfolyamai sokkal érzékenyebbek lehetnek a rövid távú eseményekre, például a gazdasági ciklusokra vagy szélsőséges történésekre. Ez a volatilitás jelentős kihívást jelent a prediktív modellek számára, hiszen nehezebb pontos előrejelzéseket készíteni olyan piacokon, ahol az árfolyamok gyorsan és nagy mértékben változhatnak. A világgazdaságot érő stresszhatások jelentősen befolyásolják a különböző pénzügyi piacok alakulását, ezért kiemelten fontos, hogy az ilyen időszakokban minél pontosabban meg lehessen becsülni a vizsgált termékek árfolyamait. A gépi tanulási modellek alkalmazásának előnyei közül ki kell emelni, hogy a többi módszerhez képest pontosabban képesek a nagy mennyiségű múltbéli adatokból felismerni a mintázatokat és

azok alapján a jövőben várható árfolyamokat, trendeket előre jelezni. A mély tanulási modellek sajátossága, hogy minél nagyobb mennyiségű adat áll rendelkezésükre, annál hatékonyabban képesek tanulni. Különösen nagy jelentősége van tehát annak, hogy milyen egyedi tulajdonságokkal bíró gazdasági periódusokból származó adatkészleten tanítjuk őket. Az alábbi kutatási kérdésekre keresem a választ:

C2: A dolgozatom második célkitűzése annak a vizsgálata, hogy a gépi tanulási modellek milyen mértékben képesek javítani a pénzügyi eszközök kereskedési teljesítményét a hagyományos buy-and-hold stratégiához képest. Az alábbi kutatási kérdésekre keresem a választ:

K4: Mennyiben képesek a gépi tanulási előrejelzéseken alapuló kereskedési stratégiák kihasználni a piaci anomáliákat, a hatékony piacok elméletével szemben?

K5: Milyen hatása van a különböző termékosztályok (pl. részvények, kriptovaluták, árupiac, devizapárok) volatilitásának a gépi tanulás által támogatott kereskedési stratégiák teljesítményére?

K6: Milyen eltérések tapasztalhatók a gépi tanuláson alapuló stratégiák teljesítményében különböző gazdasági ciklusok alatt?

Az előrejelzéseket felhasználva szabályalapú kereskedési stratégiákat alakítok ki. Ezen stratégiák teljesítményét visszatesztetem és összevetem a passzív befektetési megközelítés eredményeivel, különös tekintettel a hozamra és kockázati mutatókra (kumulatív hozam, Sharpe-mutató, stb.). A cél nem csupán a predikció pontosságának értékelése, hanem annak feltárása is, hogy a modellek által generált döntések ténylegesen eredményeznek-e javulást a kereskedési teljesítményben. Ezen keresztül választ keresek arra, hogy a gépi tanulási alapú döntéstámogatás mennyiben képes kezelni különböző piaci körülményeket (trend, volatilitás, sokkok). A dolgozat gyakorlati értéke, hogy a vizsgált megközelítés potenciális alternatívát kínál a klasszikus passzív befektetéssel szemben. Mindez különösen releváns a hatékony piacok elméletének (EMH) kontextusában, amely szerint a piaci árfolyamok minden elérhető információt tükröznek, és ezáltal lehetetlenné válik hosszú távon extra hozamot elérni bármilyen prediktív módszerrel. A dolgozatban bemutatott stratégiák, ha képesek szisztematikusan meghaladni a buy-and-hold referenciahozamot, akkor implicit módon megkérdőjelezhetik az EMH gyakorlatias érvényességét. Ezen túlmenően a stratégiák értékelésében a Sharpe-mutató maximalizálása központi szerepet kap, mivel ez a mutató a hozam és a hozam volatilitásának arányát méri, és így alkalmas a kockázattal súlyozott teljesítmény objektív összevetésére. A modellek célja tehát nem pusztán a magas hozam elérése, hanem a stabil, volatilitás-arányos profitabilitás biztosítása. Ennek vizsgálata segíthet megérteni, hogy a gépi tanulás alapú kereskedési rendszerek mennyiben tudnak értéket teremteni olyan környezetben, ahol az információ hatékonyság elvileg kizárja az arbitrázslehetőségeket.

4. ANYAG ÉS MÓDSZER

4.1. Adatok

A kutatásomban részvényindexek (S&P500, DAX, Nikkei225), áruipiaci termékek (nyersolaj-Crude, arany, ezüst), kriptovaluták (Bitcoin, Ethereum, Litecoin) és devizapárok (EUR/USD, GBP/USD, AUD/USD) napi árfolyamadatait használtam fel a 2016. január 1. és 2022. június 30. időszakra vonatkozóan. A nyersolaj, arany és ezüst esetében határidős, míg a többi termék esetében azonnali árfolyamokkal dolgoztam. Részben azért erre a periódusra esett a választás, mert itt megtalálható a nyugalmi időszak (2018), a Covid19 (2020) és a háborús krízis (2022) egyaránt, részben pedig azért, mert a kriptovaluták relatíve új terméknek számítanak a többihez képest, így az árfolyamadataik is kisebb időszakot ölelnek fel. Az összehasonlíthatóság szempontjából tehát ez tűnt a legoptimálisabb döntésnek. Az adatokat a www.finance.yahoo.com weboldalról gyűjtöttem össze, kivételt képeznek a kriptovaluták, mert ezek adatai a www.coinmarketcap.com oldalról származnak.

Az adattisztítás és az adatsorok átvizsgálása során a hiányzó adatok kezelésének problémájával is foglalkoznom kellett, melynek jelentősége elsősorban a korrelációs mátrix (1. függelék) számításánál jelentkezett, ugyanis az egyes termékek eltérő megfigyelésszámot mutattak. Ezen probléma megoldására a lineáris interpolációs módszert választottam. Az előrejelző módszerek esetében a hiányzó adatoknak nem volt jelentősége, mivel minden termékre külön-külön történt a vizsgálat. A trend és szezonális hatások kiszűrését a későbbiekben tárgyalom a volatilitás meghatározásánál. A predikciók elvégzése során a trendet és szezonalitást külön nem kezeltem, hanem ezt a modellek mintázatfelismerő képességére bízam. Ezután az adatbázisokat három részegységre bontottam. Az első vizsgált időszak egy nyugalmas gazdasági környezetre fókuszált 2016. január 1-től 2018. június 30-ig. A második a 2018. január 1. és 2020. június 30. közötti időszakot öleli fel, amely a Covid19 miatt került kiválasztásra. Míg a harmadik szintén egy gazdasági krízissel, az orosz-ukrán konfliktussal kapcsolatos, amely a 2020. január 1. és 2022. június 30. közti időintervallumot jelenti. Az időszakokkal kapcsolatos gazdasági és politikai jellemzők bemutatását a 2.8. fejezet tartalmazza. Az elemzés során ugyanis a két válságos időszak fontos tényezőként funkcionált a modellek robusztusság-vizsgálata szempontjából. Az empirikus elemzéshez felhasznált adatok leíró statisztikáit a 3., 4. és 5. táblázat tartalmazza.

3. táblázat: A vizsgált termékek 2016. január 1. és 2018. június 30. közötti időszakra vonatkozó leíró statisztikái

	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	628	2360,37	2365,41	258,18	1829,08	2872,87
DAX	632	11575,03	12002,46	1243,42	8752,87	13559,60
Nikkei225	613	19315,52	19383,84	2355,25	14952,02	24124,15
Nyersolaj	626	50,81	49,56	9,54	26,21	74,15
Arany	625	1266,21	1271,50	57,64	1073,90	1364,90
Ezüst	625	16,98	16,87	1,25	13,74	20,67
Bitcoin	912	3649,33	1187,47	4189,45	364,33	19497,40
Ethereum	911	233,20	44,89	298,89	0,92	1398,99
Litecoin	912	52,79	6,93	72,31	3,00	358,34
EUR/USD	649	1,14	1,13	0,05	1,04	1,25
GBP/USD	649	1,33	1,32	0,07	1,20	1,48
AUD/USD	649	0,76	0,76	0,02	0,69	0,81

Forrás: saját szerkesztés

Az első vizsgált időszakban (3. táblázat) a részvényt piacokon mérsékelt növekedés és viszonylag stabil volatilitás volt tapasztalható. Az S&P 500 index átlaga 2360,37 pont volt, 258,18 pontos szórással, míg a DAX és a Nikkei225 esetében magasabb átlagértékek és szórások jellemezték az időszakot, utalva az európai és ázsiai piacok nagyobb árfolyamingadozásaira. A nyersolaj átlagos ára 50,81 USD volt, azonban viszonylag magas szórással (9,54 USD), ami a nyersanyagpiac érzékenységet tükrözi a geopolitikai és kereslet-kínálati változásokra. Az arany és ezüst stabilabb értékörző eszközként viselkedtek, viszonylag alacsony szórással, különösen az ezüst esetében (1,25 USD). A kriptovaluták, különösen a Bitcoin és az Ethereum jelentős volatilitást mutattak ebben az időszakban: a Bitcoin szórása 4189,45 USD, míg az Ethereumé 298,89 USD volt. Ez a magas szórás a digitális eszközök piaci árának gyors felfutását és spekulatív jellegét mutatja. A devizapiacokon az EUR/USD, GBP/USD és AUD/USD árfolyamok viszonylagos stabilitást mutattak, alacsony szórással és szűk intervallumban mozgó minimum-maximum értékekkel. Összességében ez az időszak a hagyományos pénzügyi eszközök számára stabil, a kriptoeszközök számára pedig erőteljes növekedési és volatilitási szakasz volt.

4. táblázat: A vizsgált termékek 2018. január 1. és 2020. június 30. közötti időszakra vonatkozó leíró statisztikái

	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	628	2862,46	2843,11	195,87	2237,40	3386,15
DAX	627	12099,54	12253,15	911,70	8441,71	13789,00
Nikkei225	606	21865,58	21874,23	1291,52	16552,83	24270,62
Nyersolaj	628	56,18	58,30	13,28	-37,63	76,41
Arany	627	1394,23	1328,10	159,39	1176,20	1793,00
Ezüst	627	16,06	16,14	1,29	11,73	19,39
Bitcoin	912	7679,92	7679,97	2384,93	3236,76	17527,00
Ethereum	911	302,16	207,80	238,30	81,72	1398,99
Litecoin	912	80,24	61,06	48,48	23,46	296,45
EUR/USD	651	1,14	1,13	0,04	1,07	1,25
GBP/USD	651	1,30	1,29	0,05	1,15	1,43
AUD/USD	651	0,71	0,71	0,04	0,57	0,81

Forrás: saját szerkesztés

A második időszakban (4. táblázat), amely részben átfedi a Covid19 járvány kezdetét, a pénzügyi piacokon növekvő volatilitás és strukturális átrendeződés volt megfigyelhető. A részvényindexek különösen az S&P 500 (átlag: 2862,46) és a DAX (átlag: 12099,54) mérsékelt növekedést mutattak az előző időszakhoz képest, azonban az árfolyamok szórása enyhén csökkent, ami a piac részleges stabilizálódását jelezheti a járvány kitörése előtt. A nyersolaj piacán rendkívüli árzuhanás történt, amit jól jelez a negatív minimum érték (-37,63 USD), amely 2020 áprilisában következett be a határidős piacon. A nemesfémek, különösen az arany, felértékelődtek mint menekülőeszközök: az arany átlaga 1394,23 USD-ra emelkedett, szórása pedig jelentősen nőtt (159,39 USD). A kriptovaluták, például a Bitcoin és az Ethereum, továbbra is magas szórással bírtak, de medián értékeik emelkedése mérsékeltebb, mint korábban, ami a piac érettségének bizonyos jeleit mutatja. A Litecoin esetében szintén emelkedett az átlagár, viszonylag magas szórással. A devizák közül az EUR/USD és GBP/USD párok enyhe értékcsökkenést mutattak, míg az AUD/USD jelentősebb mértékben gyengült, ami az ausztrál gazdaság nyersanyagkitettségre vezethető vissza. Ez az időszak tehát fokozódó bizonytalanságot, de egyben alkalmazkodást is tükröz a hagyományos és új típusú pénzügyi eszközök piacán.

5. táblázat: A vizsgált termékek 2020. január 1. és 2022. június 30. közötti időszakra vonatkozó leíró statisztikái

	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	628	3851,17	3915,98	599,47	2237,40	4796,56
DAX	635	13907,57	13950,04	1633,03	8441,71	16271,75
Nikkei225	606	26031,83	27007,45	3214,96	16552,83	30670,10
Nyersolaj	628	63,11	62,57	25,23	-37,63	123,70
Arany	628	1803,00	1809,30	104,27	1477,30	2051,50
Ezüst	628	22,99	23,97	3,70	11,73	29,40
Bitcoin	911	30776,76	33798,01	18183,70	4970,79	67566,83
Ethereum	911	1745,93	1790,25	1384,34	109,21	4800,00
Litecoin	911	116,99	109,43	68,26	30,93	386,45
EUR/USD	651	1,15	1,16	0,05	1,04	1,23
GBP/USD	651	1,32	1,33	0,06	1,15	1,42
AUD/USD	651	0,72	0,72	0,04	0,57	0,80

Forrás: saját szerkesztés

A harmadik időszak (5. táblázat) erőteljes piaci változásokat hozott a Covid19 pandémia és az abból való kilábalás, majd az orosz–ukrán háború következtében kialakult geopolitikai bizonytalanság hatására. Az S&P 500 index átlaga 3851,17 pontra emelkedett, szórása viszont jelentősen, 599,47 pontra nőtt, utalva a növekvő piaci volatilitásra. A DAX és a Nikkei225 indexek szintén növekvő átlag- és maximum értékekkel bírtak, miközben volatilitásuk is emelkedett, különösen a Nikkei225 esetében. A nyersolaj piaca rendkívüli érzékenységgel reagált az orosz–ukrán konfliktusra: az árfolyam szórása 25,23 USD-ra nőtt, a maximum érték pedig elérte a 123,70 USD-t. Az orosz nyersanyagexport, különösen az energiahordozók kiesése vagy bizonytalansága kulcsszerepet játszott az árfolyam-ingadozásokban. A nemesfémek, főként az arany iránti kereslet megnőtt, mint menekülőeszköz iránt, bár az árfolyam magas szinten stabilizálódott, 1803,00 USD átlagárral. A Bitcoin és Ethereum ebben az időszakban értékük csúcsára értek: a Bitcoin átlagosan 30776,76 USD-t ért el, szórása kiugróan magas, 18183,70 USD volt. Ez részben a kockázatkerülés és a spekulatív tőkebeáramlás következménye is lehetett a hagyományos piacok ingadozása mellett. Az az EUR/USD és GBP/USD árfolyamai viszonylag stabilak maradtak, azonban az európai gazdaság közvetlen érintettsége miatt enyhe gyengülés volt megfigyelhető. Összességében ez az időszak a fokozódó geopolitikai feszültségek, az energiapiaci sokkok és a befektetői kockázatkerülés dominanciájának időszaka volt.

A vizsgálatok során egy- és többváltozós módszerekkel is végeztem kísérleteket. Az egyváltozósok esetében a napi záróárfolyamok képezték a predikció alapját, mégpedig úgy, hogy az aktuális időpontbeli árfolyamot a megelőző 50 időegység (szekvencia) adatainak alapján becsülték meg a modellek. A többváltozós vizsgálatok esetében is hasonlóan jártam el, annyi volt

a különbség, hogy a napi záró árakon túl, a nyitó, legmagasabb és legalacsonyabb árfolyamértékek is szerepet kaptak szintén 50 napos szekvenciatartományokkal.

4.2. Alkalmazott módszerek

A választott módszerek mindegyike képes regressziós és klasszifikációs módszertan alapján is dolgozni. A dolgozatomban csak a regressziós elemzésekkel foglalkozom. Az alábbiakban a modellek részletes leírása következik.

4.2.1. Simple Recurrent Neural Network (RNN)

Az RNN a mesterséges neurális hálózatok egyik típusa, amely három fő részből áll: bemeneti, rejtett és kimeneti rétegekből. A hagyományos hálózatokhoz képest két fő különbség van. Az egyik, hogy az RNN azonos rejtett rétegben lévő csomópontjai kapcsolatban állnak egymással, a másik, hogy a rejtett réteg bemenetei a jelen időpontban tartalmazzák a bemeneti réteg jelenlegi időpontban létező kimeneteit, valamint a rejtett réteg előző időpontban eltárolt kimeneteit is. Ez a speciális struktúra lehetővé teszi a dinamikus időbeli viselkedés jobb leírását egy idősor szekvencia esetén. Így tehát egy RNN felhasználhatja a korábban megtanult információkat az éppen aktuális minta felismeréséhez, ezáltal hatékonyabb modellezést tesz lehetővé (Bai et al. 2021). Az egyszerű RNN modell a következő egyenletekkel írható fel:

$$S_t = (Ux_t + WS_{t-1} + b_h) \quad (1)$$

$$y_t = f(VS_t + b_o) \quad (2)$$

ahol x_t reprezentálja a t időpontbeli inputokat, S_t rejtett réteg kimeneteit, y_t a kimeneti réteg információit, $f()$ az aktiválási függvényt, b_h és b_o rejtett és kimeneti réteg torzítási vektorait mutatja. Definálni kell továbbá a súlyozást is, amely esetében W a bemeneti értékek, U a bemeneti értékek éppen aktuális időpontbeli, míg V a kimenetek súlyát jelöli.

4.2.2. Gated Recurrent Unit (GRU)

A GRU a rekurrens neurális hálózatok (RNN) egyik típusa, amely kiemelkedő teljesítményre képes az idősorok előrejelzésében. Hasonló az általunk tárgyalt másik neurális hálós modellhez (LSTM), viszont a GRU alacsonyabb számítási kapacitásszükséglettel rendelkezik, amely nagymértékben javíthatja a tanulási hatékonyságot.

Bemeneti és kimeneti struktúrája megegyezik egy egyszerű RNN-ével. A GRU egység belső szerkezete csak két kaput tartalmaz: az z_t frissítési és az r_t reset kaput. A z_t frissítési kapu határozza meg az aktuális időponthoz mentett előző memória értékét, az r_t visszaállítási kapu pedig meghatározza, hogy az új bemeneti információt hogyan kell kombinálni az előző memória

értékével. Az LSTM algoritmussal ellentétben a z_t frissítési kapu egyszerre képes elfelejteni és kiválasztani a memória tartalmát, ami javítja a számítási teljesítményt és csökkenti a futási idő szükségletet. A GRU összefüggései a következő egyenletekkel határozhatók meg:

$$z_t = \sigma(W_z h_{t-1} + U_z x_t) \quad (3)$$

$$r_t = \sigma(W_r h_{t-1} + U_r x_t) \quad (4)$$

$$\tilde{h}_t = \tanh(W_0(h_{t-1} \odot r) + U_0 x_t) \quad (5)$$

$$h_t = z_t \odot \tilde{h}_t + (1 - z_t) \odot h_{t-1} \quad (6)$$

ahol $\sigma()$ egy logisztikus szigmoid függvény, azaz $\sigma(x) = \frac{1}{1 + e^{-x}}$; h_{t-1} a neuron utolsó pillanatbeli rejtett állapota. W_z és U_z a frissítési kapu súlymátrixai. W_r és U_r a visszaállító kapu súlymátrixai. W_0 és U_0 az ideiglenes kimenet súlymátrixai. Az x_t a bemeneti érték a t időpontban, $\tilde{h}_t$ és h_t azok az információs vektorok, amelyek rejtett réteg kimenetet és ideiglenes egységállapotot biztosítanak a t időpontban (Xiao et al. 2022). A $\odot$ (Hadamard szorzat) az elemenkénti szorzást jelöli két azonos dimenziójú mátrix között. Ez a művelet gyakori neurális hálózatoknál, különösen aktivációs vagy súlyozott kapcsolatok esetében.

4.2.3. Long-Short Term Memory (LSTM)

Az LSTM a recurrens neurális hálózatok (RNN) egyik típusa, amelyet a szekvenciális adatokkal kapcsolatos kutatásokban gyakran alkalmaznak. A hosszú távú memória a tanulási súlyokra, a rövid távú memória pedig a sejtek belső állapotaira utal. Az LSTM az RNN-ek eltűnő gradiens problémájára jött létre, amelynek fő változása az RNN középső rétegének helyettesítése egy blokkal (LSTM blokk). Az LSTM fő jellemzője a hosszú távú affiláció-tanulás lehetősége, ami az RNN-ek esetében lehetetlen volt. A következő időponthoz kapcsolódó adatok előrejelzéséhez a hálózat súlyértékeinek frissítésére van szükség, ami a kezdeti időintervallum adatainak karbantartását igényli. Egy RNN csak korlátozott számú rövid távú affilációt tudott megtanulni; azonban a hosszú távú idősorokat az RNN-ek nem tudják megtanulni. Az LSTM azonban megfelelően tudja kezelni ezeket. Az LSTM modell struktúrája rekurrens alhálózatok halmazát tartalmazza, amit memóriablokkoknak nevezünk. Minden egyes blokk tartalmaz egy vagy több autoregresszív memóriacellát és három többszörös egységet (bemenet, kimenet és felejtés), amelyek a folyamatos írás, olvasás és a sejtek működésének szabályozását végzik (Ortu et al. 2022). Az LSTM modell a következő egyenletekkel definiálható:

$$I_t = \sigma(X_t W_{xi} + H_{t-1} W_{hi} + b_i) \quad (7)$$

$$F_t = \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f) \quad (8)$$

$$\tilde{C}_t = \tanh(X_t W_{xc} + H_{t-1} W_{hc} + b_c) \quad (9)$$

$$C_t = F_t \odot C_{t-1} + I_t \odot \tilde{C}_t \quad (10)$$

$$O_t = \sigma(X_t W_{xo} + H_{t-1} W_{ho} + b_o) \quad (11)$$

ahol h a rejtett egységek száma, X_t egy adott t időegység kis tételű bemenete, H_{t-1} az előző időszaki adat rejtett állapota, σ a szigmoid függvény, W_{xi} és W_{hi} a bemeneti kapu súlymátrixa, a b_i pedig a bemeneti kapu offset tagja. W_{xf} és W_{hf} a felejtési kapu súlymátrixa, b_f a felejtési kapu offset tagja. $\tilde{C}_t$ a lehetséges memóriacellák W_{xc} és W_{hc} a kapuzott egység súlymátrixa, b_c a kapcsolt egység offset tagja. C_t az aktuális időpontban lévő új cellaállapot, C_{t-1} az előző időpontban lévő cellaállapot. W_{xo} és W_{ho} a kimeneti kapu súlymátrixa, a b_o pedig a kimeneti kapu offset tagja (Dai et al. 2022).

4.2.4. LSTM-GRU hibrid

Mind a GRU, mind az LSTM képes szelektíven emlékezni a fontos információkra és elfelejteni a lényegtelen információkat. Az LSTM a saját három kapus eszközt használja az adat- és információáramlás szabályozására a hálózaton keresztül, megoldva ezzel a hosszú távú függőség problémáját. Az LSTM hálózat által beállított paraméterek túlzott száma miatt azonban minden egyes cella 4 teljesen összekapcsolt réteggel rendelkezik. A gyakorlatban, ha nagy időintervallumról van szó, és az LSTM hálózat mély, valószínűleg túlillesztés következik be. Ez nagy számítási kapacitásigényt generál. Az LSTM-hez képest a GRU az LSTM bemeneti kapuját, felejtési kapuját és kimeneti kapuját egy frissítési kapuval és egy visszaállítási kapuval helyettesíti. A GRU az LSTM egyszerűsítése kevesebb paraméterrel, ami csökkenti a túlillesztés kockázatát. Nagy adathalmazok esetén azonban nem teljesít olyan jól, mint az LSTM. Az LSTM-en és GRU-n alapuló hibrid LSTM/GRU modell megtartja mindkét modell előnyeit, csökkenti a túlillesztést, és így lehetővé teszi a nagy pontosságú előrejelzések elérését (Zhao et al. 2023). Ebben a modellben az első rejtett réteg az LSTM. Minden egyes LSTM neuron összegyűjti az adatokat, és egy súlyozott értéket generál. Ezután az adatok az LSTM-ből a GRU rétegbe kerülnek, amely a második rejtett réteg. Az LSTM rétegtől a GRU-rétegig tartó úton ismét súlyozott értéket generálnak. Hasonlóképpen, az adatok ezután a harmadik rejtett rétegbe (sűrű réteg) kerülnek. A GRU rétegtől a sűrű rétegig szintén súlyozott értéket generálunk. A sűrű réteg egy normál neurális hálózati réteg, amely a kimenet előállítására szolgál. A sűrű rétegből az adatok ezután a kimeneti neuronhoz kerülnek (Islam és Hossain 2021).

4.2.5. RNN-LSTM hibrid

Az RNN és az LSTM erősségeinek kihasználása és gyengeségeik kiküszöbölése érdekében az RNN-LSTM hibrid modell alkalmazása jelentősen javítja az idősorok előrejelezhetőségét (Faru et al. 2023). Ennél az algoritmusnál az első rejtett réteg az RNN, melyben a neuronok összegyűjtik az információkat és egy súlyozott érték generálódik. Majd ezután az információ átkerül az RNN rétegből a második rejtett rétegbe az LSTM-be. Az RNN rétegtől az LSTM-ig tartó úton ismét súlyozott értékek generálódnak. Az adatok ezután a harmadik rejtett rétegbe (sűrű réteg) kerülnek. Az LSTM rétegtől a sűrű rétegig szintén súlyozott értékek generálódnak.

4.2.6. RNN-GRU hibrid

Bár a szakirodalomban meglehetősen sokféle hibrid algoritmus felfedezhető, ennek ellenére az RNN-GRU kombinációra kevés kutatás épít. Ez a modell nagyon hasonlít az előzőhöz, tehát az első rejtett réteg az RNN, melyben a neuronok összegyűjtik az információkat és egy súlyozott érték generálódik. Majd ezután az információ átkerül az RNN rétegből a második rejtett rétegbe az GRU-ba. Az RNN rétegtől az GRU-ig tartó úton ismét súlyozott értékek generálódnak. Az adatok ezután a harmadik rejtett rétegbe (sűrű réteg) kerülnek. A GRU rétegtől a sűrű rétegig szintén súlyozott értékek generálódnak.

4.3. Az alkalmazott szoftverek és programterv

A modellfejlesztésekhez a Python programozási nyelv (3.9-es verzió) került alkalmazásra, amelynek használatát több szempont is indokolja. Egyrészt, a Python széleskörű és gyorsan fejlődő ökoszisztémával rendelkezik, különösen az adatelemzés (pl. Pandas, Numpy) és a gépi tanulás (pl. TensorFlow, Keras, Scikit-learn, Pytorch) területén, ami lehetővé teszi a korszerű neurális hálózati modellek hatékony implementálását. Másrészt, a Python nyílt forráskódú és platformfüggetlen, így a fejlesztés és a reprodukálhatóság is költséghatékonyan biztosítható. További előny, hogy a programozási nyelv egyszerű, jól olvasható szintaxisa gyors prototípus-fejlesztést tesz lehetővé, ami különösen hasznos kutatási projektek esetén, ahol a modellek folyamatos finomhangolása szükséges. A Python mellett szólt a keretrendszerek széles választéka, a mélytanulás támogatása és az ipari alkalmazhatóság. A script-eket a Google Colab felületén, valamint lokálisan a Visual Studio Code kódszerkesztő segítségével futtattam. A programterv leírását az alábbiakban részletezem.

Programterv

A program logikáját és megvalósítási folyamatát a többváltozós LSTM modell (5. függelék) példáján keresztül mutatom be, az S&P500 index adatait alapul véve. A vizsgálatom a 2016. január

1. és 2018. június 30. közötti időszak historikus árfolyamadataira épül. Elsőként a yfinance könyvtár segítségével letöltöttem az S&P500 index (^GSPC) napi árfolyamadatait. Ez magában foglalta a nyitó, záró, minimum és maximum árakat minden vizsgált időszakra. Az adatokat Pandas DataFrame-be töltöttem, majd megkezdtem az előkészítést. A kiválasztott jellemzőket (High, Low, Open, Close) a MinMaxScaler algoritmus segítségével normalizáltam 0 és 1 közé, a modell tanítási hatékonyságának növelése érdekében. A záróárhoz külön skálázót hoztam létre, hogy az előrejelzéseket vissza tudjam alakítani az eredeti értéktartományba. Meghatároztam egy szekvenciahossz-paramétert (sequence_length = 50), amely megadja, hogy hány múltbéli időpont adatát használom fel egyetlen előrejelzéshez. A partition_dataset függvénnyel az adatokat betanító és tesztelő szettekbe osztottam, 80–20%-os arányban, figyelembe véve a szekvenciahatárokat is. Ezután felépítettem a modell struktúráját egy Keras-alapú szekvenciális neurális hálózat formájában. A hálózat két rejtett LSTM réteget tartalmazott ReLU aktivációval, amelyeket egy sűrű (Dense) kimeneti réteg követett, egyetlen neuronnal, amely az árfolyamok előrejelzéséért felelt. A modellhez továbbá „adam” optimalizálót és „mean squared error” (MSE) veszteségfüggvényt használtam. Ezután a modellek tanítása következett (x_train, y_train) 100-as epoch (az egész képzési adathalmaz teljes feldolgozását jelenti a tanulási algoritmus által), 16-os batch méret mellett. A validációs teljesítményt a tesztadatokon mértem és a túlilleszkedés elkerülése érdekében beépítettem egy EarlyStopping callbacket, amely leállítja a tréninget, ha a validációs hiba nem javul több egymást követő epoch során. A modell kiértékeléséhez előrejelzéseket készítettem a tesztadatokra, majd az eredményeket a korábban létrehozott skálázóval visszatranszformáltam az eredeti értéktartományba. Az előrejelzések pontosságát és az illeszkedést több metrikával (MAE, MSE, MAPE, MDAPE, R^2) vizsgáltam, amelyek átfogó képet adnak a modell teljesítményéről. Az eredményeket vizuálisan is megjelenítettem, ami ellenőrző lépésként szolgált, hogy nem történt-e valamilyen anomália az előrejelzések során. Grafikonokat készítettem a tanulási és validációs hiba alakulásáról is, valamint idősoros ábrákat a tényleges és előrejelzett árfolyamokról. Ábrázoltam a reziduumokat, azaz a tényleges és becslt értékek közötti eltéréseket, a modell pontosságának mélyebb megértése, valamint a túl- vagy alulbecslések ellenőrzése érdekében. Végül az előrejelzések eredményeit Excel formátumba mentettem, hogy további statisztikai elemzéseket és dokumentációs célú archiválást is el tudjak végezni.

A folyamatot a többváltozós LSTM modellel az S&P500 index példáján keresztül szemléltettem. Hasonlóan jártam el a többi alkalmazott modell esetében is figyelembe véve minden időszakot és terméket. A hibrid modelleknél a két rejtett neuron réteget alakítottam a megnevezések szerinti sorrendben, tehát az LSTM-GRU esetében az első rejtett rétegbe az LSTM, míg a másodikba a GRU algoritmus került.

4.4. 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 becsült 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.

4.5. Hiperparaméterek

A kutatásba bevont modellek hiperparamétereit a 6. táblázat tartalmazza. A hibrid típusoknál is ugyanezek kerültek felhasználásra. A kutatómunka során hiperparaméter optimalizálás nem valósult meg többek között azért, mert ez jelentős számítási kapacitás igényt generált volna. Az aranyközéputat választva a szakirodalmi adatbázis alapján a leggyakrabban alkalmazott értékeket állítottam be a modellekhez.

6. táblázat: Az alkalmazott modellek hiperparamétereit

Modell	Parameter	Érték
RNN	Rejtett rétegek száma	2
	Rejtett rétegek neuronjainak száma	150
	Batch méret	16
	Iterációk száma	100
	Aktivációs függvénye	ReLU
	Tanulási ráta	0,001
	Optimalizáló	Adam
LSTM	Rejtett rétegek száma	2
	Rejtett rétegek neuronjainak száma	150
	Batch méret	16
	Iterációk száma	100
	Aktivációs függvénye	ReLU
	Tanulási ráta	0,001
	Optimalizáló	Adam
GRU	Rejtett rétegek száma	2
	Rejtett rétegek neuronjainak száma	150
	Batch méret	16
	Iterációk száma	100
	Aktivációs függvénye	ReLU
	Tanulási ráta	0,001
	Optimalizáló	Adam

Forrás: saját szerkesztés

4.6. Adatbázis felosztás, keresztvalidáció és túlillesztés

A modellezéshez a tanuló és tesztelő adatbázisokat 80%-20%-os arányban osztottam fel, mely a szakirodalomban a leggyakrabban alkalmazott módszer. Az előrejelezni kívánt időszakok így minden terméktípus és vizsgálati periódus (2018, 2020, 2022) esetében is január 1-je és június 30-a közé estek, tehát ez az időszak tekinthető a tesztelő fázisnak, míg az ezt megelőző a tanuló adatbázist fedi le. Ez a felosztás a változó adatbázis méretek és a termékek kereskedési sajátosságai miatt az alábbi előrejelzési időhorizontokat határozta meg napokban (7. táblázat).

7. táblázat: Előrejelzési időhorizontok az egyes időszakokban

Termék	Előrejelzési ablak (nap)		
	2018	2020	2022
S&P500	125	125	123
DAX	125	125	126
Nikkei225	121	119	119
Nyersolaj	125	125	123
Arany	124	125	123
Ezüst	124	125	123
Bitcoin	181	182	180
Ethereum	180	182	181
Litecoin	181	182	180
EURUSD	130	130	128
GBPUSD	130	130	128
AUDUSD	130	130	128

Forrás: saját szerkesztés

4.6.1. Keresztvalidáció

A keresztvalidáció egy statisztikai módszer, amelyet a gépi tanulási modellek teljesítményének értékelésére használnak. A folyamat során az adatokat több részre osztják, majd az egyes részeket felváltva használják tanításra és tesztelésre. Ez segít abban, hogy a modell általánosíthatóságát és megbízhatóságát jobban meg lehessen becsülni (Bergmeir és Benítez, 2012). A keresztvalidációhoz az úgynevezett rolling window módszert használtam, amely egy hatékony technika az idősoros adatok esetében. Ez a módszer segít abban, hogy a modell teljesítményét folyamatosan értékeljük és biztosítsuk, hogy az jól tudjon általánosítani és adaptálódni az új adatokra is. A rolling window módszer lényege, hogy az adathalmazt mozgó ablakokkal osztjuk fel tréning és teszt szettekbe. Minden egyes iterációban az ablak egy lépéssel előre mozdul, így az újabb adatok kerülnek a tréning szettbe, míg a legrégebbi adatok kikerülnek belőle. Ezáltal a modell folyamatosan friss adatokon tanul és tesztel (Hirano és Wright, 2022).

A módszer előnyei a következők:

- Idősoros adatok kezelése: A rolling window módszer különösen hasznos az idősoros adatok esetében, mivel figyelembe veszi az adatok időbeli sorrendjét (Inoue et al., 2017).
- Általánosítás javítása: A módszer segít abban, hogy a modell jobban általánosítson új adatokra, mivel folyamatosan friss adatokon teszteljük (Vu et al., 2022).
- Stabilitás és robusztusság: A rolling window módszer növeli a modell stabilitását és robusztusságát, mivel a tréning szett folyamatosan változik (Matsunaga et al., 2019).

4.6.2. Túlillesztés

A gépi tanulási modellek különösen jók a mintafelismerésben. Sokszor annyira jól működnek, hogy gyakran olyan összefüggéseket felfedeznek, ami valójában nem létezik az adatsorunkban. Erre kiváló példa, mikor túltanítjuk a modellt (Petrini et al., 2023). Ilyenkor a modellek megtanulnak minden apróbb eltérést a tanuló adatbázisból és képzelt mintákat fedeznek fel benne, majd ezek a fals minták beépülnek. Másképpen fogalmazva specializálódnak a tanuló adatokra. Ezzel az a gond, hogy nem lehet általánosítani a modellt. Ezt nevezzük túlillesztés is problémának. A neurális hálózati módszerek különösen hajlamosak a túlillesztésre (Xie et al., 2021).

A probléma lehetséges megoldásai közé tartozik, hogy az összetettebb modelleket valamivel büntetjük, így megakadályozzuk a túlságosan szélsőséges tanulást. Még nagyobb adatmennyiséget használunk a tanítás során, ezáltal nehezebben találják meg azokat a valótlan mintázatokat, amelyek torzíthatják a modellt. A harmadik lehetőség az úgynevezett dropout réteg alkalmazása, amely ezt a problémát úgy oldja meg, hogy véletlenszerűen deaktivál egy bizonyos százalékot a neuronokból minden egyes tréninglépés során (Santos és Papa, 2022; Bejani és Ghatee, 2021).

A dropout réteg működése:

- Véletlenszerű deaktiválás: a dropout réteg véletlenszerűen kiválasztja a neuronokat, amelyeket ideiglenesen kikapcsol a tréning során. Ez azt jelenti, hogy a kiválasztott neuronok nem vesznek részt az adott tréninglépésben (Chen és Yi, 2021).
- Robusztusabb jellemzők tanulása: mivel a neuronok véletlenszerűen deaktiválódnak, a modell kénytelen többféle jellemzőt megtanulni, nem támaszkodhat egyetlen neuronra vagy jellemzőre. Ezáltal a modell robusztusabbá válik (Salman és Liu, 2019).
- Általánosítás javítása: a dropout réteg segít abban, hogy a modell jobban általánosítson új adatokra, mivel csökkenti a túlillesztés kockázatát. Ez különösen fontos a pénzügyi előrejelzésekben, ahol a modelleknek képesnek kell lenniük jól teljesíteni változó piaci körülmények között is (Montesinos López et al., 2022).


A szakirodalom alátámasztotta, hogy a dropout réteget használata fontos a neurális modellek esetében, ezért én is alkalmaztam, ezt a megoldást a modellalkotás során.

4.7. Aktivációs függvények

Az aktivációs függvények nagyon fontos szerepet játszanak a neurális hálózati modellek működésében, mivel az absztrakt jellemzőket nemlineáris transzformációkon keresztül tanulják meg. Az aktivációs függvények néhány közös tulajdonsága a következő (Dubey et al., 2022):

- hozzá kell adnia a nemlineáris görbületet az optimalizációs tartományhoz, hogy javítsa a hálózat képzési konvergenciáját
- nem növelheti jelentősen a modell számítási komplexitását
- nem akadályozhatja a gradiensek áramlását a tanulási folyamat során
- meg kell tartania az adatok eloszlását a hálózat jobb képzésének megkönnyítése érdekében.

A három leggyakrabban alkalmazott alapvető aktivációs függvény (26. ábra) a ReLU (Rectified Linear Units), a Sigmoid és a hiperbolikus tangens (tanh).



26. ábra: A ReLU, a Sigmoid és a Tanh aktivációs függvények

Forrás: Wang et al. (2020)

4.7.1. ReLU

A ReLU (egyenirányított lineáris egység) egy gyakran használt aktivációs függvény, amely pozitív bemenet információ esetén az identitás függvényt adja vissza, míg negatív bemeneti adatnál nulla visszatérési értékkel rendelkezik. Ezért a ReLU tartománya $(0, \infty)$. A ReLU függvény megoldást nyújt a Sigmoid és a Tanh függvények (lásd 4.5.2. és 4.5.3. alfejezet) számítási bonyolultságának problémájára. A ReLU hátránya, hogy a negatív bemenetek esetében a gradiens eltűnik, ennek ellenére az egyik legszélesebb körben alkalmazott aktivációs függvény a mélytanulási modellek területén. Kiszámítása a következőképpen történik (Dubey et al., 2022):

$$\text{ReLU}(x) = \max(0, x)$$

4.7.2. Sigmoid

A Sigmoid egy nagyon népszerű és hagyományos nemlineáris aktivációs függvény. A bemeneti adatokat 0 és 1 közé szorítja. A Sigmoid kimenete magasabb és alacsonyabb bemenetek esetén telített, ami eltűnő gradiens problémához vezet. Ez a probléma egy olyan forgatókönyvet mutat be, ahol a célfüggvény gradiense egy paraméterrel szemben nagyon közel kerül a nullához, és a hálózat sztochasztikus gradiens ereszkedési technikával történő képzése során a paraméterek szinte semmilyen frissítését nem teszi lehetővé. A kimenet nem követi a nulla centrikus jelleget, ami ezáltal gyenge konvergenciához vezet. A függvény a következőképpen definiálható (Dubey et al., 2022):

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

4.7.3. Tanh

A Tanh függvényt szintén gyakran használják a neurális hálózati modellezés során. Nagyon hasonlít a fent bemutatott sigmoid függvényhez, azonban az a legnagyobb különbség, hogy ez egy nullára centrált függvény. A Tanh függvény szintén összenyomja a bemeneti adatokat, csak ebben az esetben a tartomány a -1 és 1 közé esik. A Tanh alkalmazása során is megfigyelhetők olyan hátrányok, mint például az eltűnő gradiens és a számítási komplexitás. A Tanh függvényt a következőképpen határozhatjuk meg (Dubey et al., 2022):

$$\text{Tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

4.8. Volatilitás vizsgálata

Az eltérő termékek és időszakok szórás adatai nem megfelelőek a volatilitás és a MAPE értékek összehasonlítására, ezért szükséges volt a relatív volatilitást mérő mutató alkalmazására, amelynek kiszámítását az alábbiakban részletezem. Elsőként olyan módszert kellett találni, amely az idősorokban azonosítja a trendeket és el is tudja azokat távolítani, mivel ezek torzíthatják az eredményeket. Ehhez a Seasonal-Trend decomposition using Loess-t (STL) megközelítést használtam. A módszertan részletes leírását a továbbiakban tárgyalom.

4.8.1. STL (Seasonal-Trend decomposition using Loess)

Az STL egy rugalmas idősoelemzési módszer, amely a vizsgált sorozatot három komponensre bontja: a hosszú távú trendre, a szezonális mintázatra és a véletlenszerű reziduumba. Az STL különlegessége a LOESS (Locally Weighted Scatterplot Smoothing) használata, amely képes a

nemlineáris, időben változó szezonális mintázatok modellezésére is. Előnye továbbá a robusztusítása és rugalmassága, így jól alkalmazható például pénzügyi idősorok elemzésénél. Az idősor dekompozíciója az alábbi formában történik:

$$Y_t = T_t + S_t + R_t$$

ahol Y_t az eredeti idősor, T_t a trend, S_t a szezonális komponens, R_t pedig a reziduum. Az STL hatékonyan alkalmazható pénzügyi idősorokon, ahol a szezonális mintázatok idővel változhatnak (Cleveland et al., 1990). A reziduum R_t tartalmazza a rövid távú, trendtől független fluktuációkat, ezért e komponens alkalmas volatilitásvizsgálatra (He et al., 2021).

4.8.2. Relatív volatilitás: variációs koefficiens (CV)

A trendmentesített sorok volatilitását a variációs koefficiens (CV) segítségével mértem. A CV egy dimenzió nélküli mutató, amely lehetővé teszi különböző mértékegységű és nagyságrendű eszközök szórásának összehasonlítását. A képlete a következő:

$$CV = \frac{\sigma(R_t)}{\mu(Y_t)}$$

ahol $\sigma(R_t)$ a reziduális komponens szórása, míg $\mu(Y_t)$ az eredeti idősor átlaga. A mutató érzékeny a sor átlagának nagyságára, így alacsony nominális értékű eszközöknél a CV nagyobb volatilitást mutathat. A CV egyensúlyt teremt az abszolút és relatív szórásalapú volatilitásmérés között és jól alkalmazható klaszteranalízis alapjaként (Brockwell és Davis, 2002).

A relatív volatilitás, tehát az említett módszer (STL) reziduális komponenseiből kerül kiszámításra. Az STL esetében trend és szezonálismentes reziduumokat kapunk. A számított értékeket az 7. függelék tartalmazza.

4.9. Predikció alapú, dinamikusan optimalizált kereskedési stratégia

Az általam alkalmazott algoritmus (6. függelék) egy gépi tanulási előrejelzésen alapuló, paraméter-érzékeny kereskedési stratégia implementálása, amely a klasszikus buy-and-hold megközelítéssel kerül összehasonlításra. A stratégia központi eleme, hogy a predikciós és valós árfolyamértékek közötti reláció alapján generál kereskedési pozíciókat, majd különböző stop-loss (SL), take-profit (TP) és volatilitás-becslési ablak (VOL_LOOKBACK) értékekkel optimalizálja a hozam/kockázat arányt. A célja tehát, hogy a kereskedési teljesítményt a Sharpe-mutató szerint maximalizálja. A forrásprogram bemenetét egy többlapos Excel fájl adja, amely instrumentumonként tartalmaz: időbélyeget („Dátum”), valós piaci értékeket (záróárak), becsült értékeket, amelyeket a predikciós modellek generálnak. A stratégia abból indul ki, hogy ha a becsült érték egy adott időpillanatban magasabb, mint a tényleges érték, akkor az árfolyam

várhatóan növekedni fog, tehát long pozíciót érdemes felvenni. Ellenkező esetben short pozíció indokolt. Ez formálisan a következőképpen írható le: ha $\hat{P}_t > P_{t-1}$, akkor long pozíciót nyit, amennyiben $\hat{P}_t < P_{t-1}$

A log hozam kiszámítása a következőképpen történik: $r_t = \ln\left(\frac{P_t}{P_{t-1}}\right)$

A stratégiát tovább finomítja egy volatilitásalapú kockázatkezelés, amelyhez három paraméter kerül beállításra:

- **SL_MULTIPLIER**: stop-loss küszöb aránya az előző időszak volatilitásához képest.
- **TP_MULTIPLIER**: take-profit küszöb aránya.
- **VOL_LOOKBACK**: az a periódushossz, amely alapján a volatilitást számítjuk (meghatározott nappal számolt mozgó szórás).

A volatilitás és határértékek így kerülnek számításra:

$$\sigma_t = std_{rolling}(r_t, VOL_LOOKBACK)$$

$$SL_t = SL_MULTIPLIER * \sigma_t$$

$$TP_t = TP_MULTIPLIER * \sigma_t$$

A realizált hozam ezek alapján lesz módosítva, ha a nyereség vagy veszteség eléri a meghatározott szinteket. Például, ha long pozícióban a hozam meghaladja a TP-t, akkor a hozamot levágjuk TP értéken; ha veszteség SL alá esik, akkor levágjuk -SL értéken. Ugyanez fordítva short pozícióra.

Erre az alap stratégiára építve két másik módszert is beépítettem és teszteltem is. Az egyik esetben 5 napos gördülő MAPE mutatót számol és csak akkor nyit pozíciót az algoritmus, ha meghatározott küszöbérték alatt van az eltérés mutató. Jelen esetben 3%-ot állapítottam meg, tehát egyfajta szűrőként működik itt a MAPE a pozíciónyitáshoz. A másik alternatív is a gördülő MAPE mutató értékét használja csak a dinamikus pozícióméret meghatározásához. Mégpedig úgy, hogy nagyobb MAPE esetén kisebb pozícióméretet vesz fel, míg ellenkező esetben nagyobb méretű allokációt valósít meg.

A program statikus és kumulatív teljesítményelemzést végez a `calculate_stats()` függvény segítségével, amely minden egyes paraméterkombináció és vizsgált instrumentum esetén kiszámítja a legfontosabb statisztikai mutatókat. Ezek közé tartozik az átlagos napi hozam (μ), a napi hozam szórása (σ), valamint a Sharpe-mutató, amelyet a szokásos évesített képlet alapján számítunk: $\frac{\mu}{\sigma} * \sqrt{252}$. Ezen túlmenően a függvény kiszámítja a kumulált hozamot, a maximális visszaesést (drawdown), amely a kumulált hozamgörbe lokális maximumai és mélypontjai közötti legnagyobb különbséget jelenti, valamint a nyertes ügyletek arányát (winrate). A számításokat a buy-and-hold benchmark stratégiára és a dinamikusan kezelt stratégiára külön-külön végzi el,

lehetővé téve a két megközelítés többdimenziós összehasonlítását. Az optimalizációs eljárás során az algoritmus egy előre meghatározott paraméterrácson keresztül iterál. Ez a rács a következő értékeket tartalmazza: $SL \in \{0.5, 1.0, 1.5\}$, $TP \in \{1.5, 2.0, 3.0\}$, és $VOL_LOOKBACK \in \{10, 20, 30\}$. Az összes lehetséges kombinációra – összesen 27 esetben – lefuttatásra kerül a stratégia, majd a rendszer kiválasztja azt a paraméterkonfigurációt, amelynél a Sharpe-mutató a legmagasabb. Az így meghatározott beállítás az adott instrumentumra optimalizált paraméterkészletként kerül eltárolásra. Az eredmények tárolása és vizualizációja is rendszerezett módon történik. Minden instrumentumhoz külön Excel-fájl készül, amely két munkalapot tartalmaz: az első („Data”) az időbeli pozíciókat, hozamokat és egyéb vonatkozó adatokat tartalmazza, míg a második („Stats”) a kiszámított statisztikai mutatókat gyűjti össze. Az összesített teljesítménymutatók egy közös Excel-fájlba is bekerülnek („Összesített_eredmények.xlsx”), amely tartalmazza az instrumentum nevét, a buy-and-hold stratégia kumulált hozamát, Sharpe-mutatóját, maximális visszaesését és winrate-jét, valamint ugyanilyen mutatókat a kialakított stratégiákra. Ezen felül rögzítésre kerülnek az adott instrumentumhoz tartozó optimalizált SL, TP és VOL_LOOKBACK paraméterek is. Az elemzés végén az algoritmus grafikus összehasonlítást végez oszlopdiagram formájában. Ez az ábra minden instrumentum esetén bemutatja a négy stratégia kumulált hozamait. Ennek segítségével jól láthatóvá válik, hogy a modell képes-e konzisztensen felülmúlni a passzív befektetési stratégiát, vagyis van-e gyakorlati értéke a predikciós modellre épített, paraméterhangolt kereskedési megközelítésnek.

Összegzésként elmondható, hogy a program egy általánosan alkalmazható eszköz predikcióalapú befektetési stratégiák elemzésére. Legfőbb jellemzői közé tartozik a prediktív komponens explicit integrálása, a parametrikus kockázatkezelés alkalmazása, valamint az automatikus optimalizáció és a klasszikus buy-and-hold benchmark stratégiával való szisztematikus összehasonlítás. A kód nemcsak szimulációs környezetben használható, hanem backtesting rendszerekhez, gépi tanulási modellek validálásához és érzékenységvizsgálatokhoz is hatékonyan adaptálható.

A kereskedési stratégiák alkalmazása során hasonlóan a legtöbb szakirodalomhoz itt sem vettem figyelembe az adókat, tranzakciós és egyéb költségeket, tehát az eredmények a bruttó kumulált hozamokat reprezentálják.

5. EREDMÉNYEK

A kutatás során felhasznált termékadatok leíró statisztikáit az előrejelzett időszakokra vonatkozóan a 7-9. táblázatok tartalmazzák.

A 2018-as előrejelzési időszakban (8. táblázat) a globális piacokon alapvetően a 2017-es fellendülést követő konszolidációs szakasz volt megfigyelhető. Az S&P 500 index átlagosan 2717,94 ponton mozgott, viszonylag alacsony szórással (61,56), ami viszonylag stabil piaci környezetre utal. A DAX és a Nikkei225 indexek ehhez hasonló mintázatot mutattak, különösen a DAX esetében 412,63 pontos szórás figyelhető meg, ami mérsékelt volatilitásra utal. A nyersolaj piaca ebben az időszakban kiegyensúlyozott volt: az árfolyam 65,46 USD körül mozgott, minimális kilengéssel. Az arany és ezüst piaci stabilitást sugalltak, alacsony szórás mellett. A kriptovaluták azonban teljesen más piaci dinamikát mutattak: a Bitcoin 9159,78 USD átlagértéke mellett jelentős, 2340,45 USD szórással rendelkezett, az Ethereum pedig még inkább volatilisnek bizonyult. A Litecoin esetében is kiugró ingadozás volt tapasztalható, ami a spekulatív kereskedés magas szintjére utal. A főbb devizapárok (EUR/USD, GBP/USD, AUD/USD) stabilnak bizonyultak, minimális szórás és változékonyság mellett, a jegybanki politikák viszonylagos kiszámíthatóságának köszönhetően.

8. táblázat: A nyugalmi időszak leíró statisztikái (2018. január 1. és 2018. június 30. között)

	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	125	2717,94	2720,94	61,56	2581,00	2872,87
DAX	125	12656,09	12590,43	412,63	11787,26	13559,60
Nikkei225	121	22341,05	22304,51	809,92	20617,86	24124,15
Nyersolaj	125	65,46	65,25	3,46	59,19	74,15
Arany	124	1316,73	1319,65	23,93	1247,80	1362,40
Ezüst	124	16,59	16,49	0,33	15,95	17,55
Bitcoin	181	9159,78	8716,79	2340,45	5903,44	17527,00
Ethereum	180	712,30	680,42	230,27	369,40	1398,99
Litecoin	181	157,42	149,87	46,08	74,93	296,45
EUR/USD	130	1,21	1,23	0,03	1,15	1,25
GBP/USD	130	1,38	1,39	0,03	1,31	1,43
AUD/USD	130	0,77	0,77	0,02	0,73	0,81

Forrás: saját szerkesztés

A 2020-as előrejelzési időszak (9. táblázat) a Covid19 járvány első hullámával és annak globális gazdasági hatásaival esett egybe, amely alapjaiban változtatta meg a pénz- és árupiacok dinamikáját. Az S&P 500 index átlaga 2993,28 pont volt, ugyanakkor a 279,02 pontos szórás magas volatilitásra utal. A DAX index még kifejezettebb volatilitást mutatott, 1483,26 pontos szórással, míg a Nikkei225 hasonló mozgásokat produkált. A nyersolaj piaca extrém kilengéseket

mutatott, negatív minimum értékkel (-37,63 USD), ami az amerikai WTI típusú olaj határidős jegyzéseinek drámai összeomlására utal. Ezt a rendkívüli piaci stresszhelyzetet jól mutatja a 15,48 USD szórás is. Az arany, mint menekülőeszköz, megerősítette státuszát: az átlagár 1650,53 USD volt, emelkedő pályát mutatva. A kriptovaluták is stabilizálódni látszottak a 2018-as esések után; a Bitcoin 8466,64 USD körüli szintet tartott, míg az Ethereum és Litecoin jelentősen alacsonyabb árfolyamokon mozgott, de kevésbé voltak volatilisak, mint korábban. A devizapiacokon mérsékelt mozgások voltak jellemzők: a főbb valutapárok enyhe gyengülést mutattak a dollár javára.

9. táblázat: A Covid19 időszak leíró statisztikái (2020. január 1. és 2020. június 30. között)

	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	125	2993,28	3029,73	279,02	2237,40	3386,15
DAX	125	11739,74	11949,28	1483,26	8441,71	13789,00
Nikkei225	119	21283,89	21530,95	2052,65	16552,83	24083,51
Nyersolaj	125	36,82	37,12	15,48	-37,63	63,27
Arany	125	1650,53	1665,40	79,68	1477,30	1793,00
Ezüst	125	16,68	17,48	1,62	11,74	18,87
Bitcoin	182	8466,64	8867,22	1300,77	4970,79	10326,05
Ethereum	182	194,35	199,58	42,00	109,21	282,92
Litecoin	182	50,26	45,49	11,97	30,93	82,99
EUR/USD	130	1,10	1,10	0,02	1,07	1,14
GBP/USD	130	1,26	1,26	0,04	1,15	1,33
AUD/USD	130	0,66	0,66	0,03	0,57	0,70

Forrás: saját szerkesztés

A 2022-es előrejelzési időszakban (10. táblázat) a gazdaság új kihívásokkal nézett szembe, különösen az inflációs nyomás, a monetáris szigorítás és a 2022 februárjában kirobbant orosz–ukrán háború következtében kialakult bizonytalanságok révén. Az S&P 500 index jelentősen emelkedett, 4288,82 ponton állt, bár a volatilitás is nőtt (270,80). A DAX és a Nikkei225 indexek szintén magasabb árszinteket értek el, miközben az árfolyam-ingadozások is fokozódtak. A nyersolaj ára jelentős növekedést mutatott (átlagosan 101,73 USD), ami egyértelműen az orosz energiahordozókhoz kapcsolódó kínálati zavaroknak tudható be. Az arany és ezüst szintén magasabb szinteken stabilizálódtak, utalva a geopolitikai kockázatokra. A Bitcoin újabb árfolyamrekordokat ért el ebben az időszakban, átlagosan közel 37 ezer USD körüli értékkel és 7310,88 USD szórással, amely jelentős volatilitást tükröz. Az Ethereum és a Litecoin hasonló árfolyam-mintázatokat mutattak, utóbbi mérsékelt szórással. A devizapiacokon újra megfigyelhető a dollár dominanciája, különösen az EUR/USD és GBP/USD párok enyhe leértékelődése révén.

10. táblázat: Az orosz-ukrán konfliktus időszakának leíró statisztikái (2022. január 1. és 2022. június 30. között)


	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	123	4288,82	4349,93	270,80	3666,77	4796,56
DAX	126	14433,83	14316,36	855,05	12831,51	16271,75
Nikkei225	119	27026,91	26987,44	864,20	24717,53	29332,16
Nyersolaj	123	101,73	103,41	11,86	76,08	123,70
Arany	123	1875,29	1854,80	58,31	1784,90	2040,10
Ezüst	123	23,40	23,20	1,56	20,67	26,89
Bitcoin	180	36969,74	39175,91	7310,88	19017,64	47686,81
Ethereum	181	2574,40	2774,37	692,60	902,25	3826,65
Litecoin	180	100,79	107,35	28,29	43,30	151,67
EUR/USD	128	1,09	1,09	0,03	1,04	1,15
GBP/USD	128	1,30	1,31	0,05	1,20	1,37
AUD/USD	128	0,72	0,72	0,02	0,69	0,76

Forrás: saját szerkesztés

5.1. Terméktípusok szerinti eredmények


5.1.1. Részvénypiac

A részvénypiaci elemzésbe három részvényindexet vontam be. Az S&P500, a DAX és a Nikkei225 mindegyike népszerű és gyakran használt benchmark instrumentum a hasonló kutatásokban. A 27. és 28. ábra szemlélteti az S&P500 alakulását, valamint a legjobban és legkevésbé illeszkedő prediktív modellek becsült adatait. Előbbin az egyváltozós, míg utóbbin a többváltozós módszerek eredményei láthatók. A MAPE értékek tehát a valós és a becsült értékek eltéréseiből származtathatók a módszertani fejezetben bemutatott formula alapján. Az egyváltozós esetben az LSTM becslése közelíti a leginkább a valós árfolyamot, ellenben a GRU-val, ami a legkevésbé pontos. A többváltozós modellezésnél viszont pont az ellenkezője történik, mégpedig, hogy a GRU a legpontosabb és az LSTM a leginkább gyengén teljesítő.



27. ábra: Az S&P500 alakulását, valamint az LSTM (legjobb) és GRU (legrosszabb) egyváltozós modellek előrejelzéseinek alakulást mutatja a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés




28. ábra: Az S&P500 alakulását, valamint az LSTM (legrosszabb) és GRU (legjobb) többváltozós modellek előrejelzéseinek alakulást mutatja a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A 29. ábra már az indexek 2018. első félévére vonatkozó előrejelzéseinek MAPE értékeit tartalmazza. Az egyváltozós modellezés során a legpontosabb prediktív teljesítményt az S&P500 esetében az LSTM és az LSTM-GRU érte el 0,0080-as MAPE értékkel, melytől a másik hibrid módszer az RNN-GRU csak minimálisan maradt el (0,0083). A legpontatlanabb pedig a GRU volt (0,0150). A DAX árfolyamát vizsgálva azt tapasztaltam, hogy itt viszont a GRU algoritmus emelkedett ki a (0,0089), míg az RNN-GRU bizonyult a leggyengébbnek (0,0138). A Nikkei225-tel végzett predikció eredményei a MAPE mutatók tekintetében a 0,0082 és a 0,0250 között mozogtak. Előbbit a legegyszerűbb modell az RNN, míg utóbbit egy vegyes módszertannal az RNN-GRU-val sikerült elérni.

A többváltozós modellezéssel jelentősen csökkentek a MAPE értékek. Az S&P500-nál tovább javult a hatékonyság, a legjobbnak a GRU (0,0078), a legrosszabbnak meglepetésre az LSTM bizonyult (0,0129). A DAX-nál is tapasztalható volt előrelépés a korábbi 0,0089-ről 0,0087-re, ami a top teljesítményt illeti és mindegyiket a GRU módszerrel sikerült elérni. Az utolsó helyet ezúttal az LSTM-GRU modell szerezte meg 0,0137-tel, ami szintén javulásnak számít az egyváltozós becsléshez képest. A Nikkei225-nél három mély tanulási algoritmus (LSTM, LSTM-GRU, RNN-GRU) is nagyjából ugyanazt a 0,0083-as értéket tudta produkálni. A legpontatlanabb pedig az RNN-LSTM hibrid lett (0,0131). Összességében elmondható, hogy a 2018-as prediktív modellezésnél a többváltozós algoritmusok alkalmazása javítani tudta a teljesítményt.




29. ábra: A részvénypiaci előrejelzések MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A Covid-járvány terjedése jelentős volatilitást okozott a részvénypiacokon, ami az előrejelzéshez használt modellek teljesítményét is befolyásolta (30. ábra). Az egyváltozós vizsgálatok során az S&P500-nál figyelhető meg a leginkább stabil teljesítmény. Ebben az esetben a legjobb (LSTM-GRU 0,0189) és a legrosszabb (LSTM 0,0204) prediktív teljesítmény között minimális eltérést tapasztaltam. Ezen időszakban a DAX tekinthető a legproblémásabbnak. A GRU algoritmus is csak 0,0253 feletti hibaértékkel volt képes dolgozni. Az RNN-LSTM pedig 0,0367-es becslési eltérést mutatott. A Nikkei225 esetében a legalacsonyabb MAPE mutatót az LSTM (0,0174), a legmagasabbat pedig az RNN-LSTM (0,0284) érte el.

A többváltozós modellek alkalmazásával az S&P500 index esetében a GRU modell (0,0182) bizonyult a leghatékonyabbnak, míg az LSTM produkálta a leggyengébb teljesítményt 0,0209-cel. A DAX indexnél a GRU modellre pozitívan hatott a további magyarázó változók bevonása, mert 0,0224-es értékkel a legjobb eredményt érte el. Az eredmények alátámasztják, hogy a legpontatlanabb az RNN algoritmus lett (0,0396). A hagyományos GRU és az RNN-GRU hibrid változat egyaránt 0,0177-es teljesítménnyel a két legoptimálisabb modellnek tekinthető a Nikkei225 2020. első féléves előrejelzései szempontjából. A legmegbízhatatlanabbnak pedig az RNN bizonyult 0,0257-es értékkel. Fontos kiemelni, hogy csak a japán index esetében csökkent a MAPE értékek felső intervallum határa, ami arra utal, hogy abszolút teljesítményben a többváltozós modellek alkalmazása nem jelentett előrelépést az egyváltozósakhoz képest.




30. ábra: A részvénypiaci előrejelzések MAPE mutatói a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés

A harmadik előrejelzési időablak 2022. első felévére vonatkozik. Ez is egy gazdaságilag stresszes időszaknak tekinthető az orosz-ukrán háború kirobbanása miatt. A 31. ábra az erre vonatkozó vizsgálati eredményeket tartalmazza. Az egyváltozós predikciók során a legpontosabb prediktív teljesítményt az S&P500 index esetében az RNN-GRU érte el 0,0144-es MAPE értékkel, melytől az LSTM csak minimálisan maradt el (0,0145). A legpontatlanabbnak az RNN bizonyult (0,0226). A DAX árfolyamának modellezése esetén azt tapasztaltam, hogy a GRU algoritmus emelkedett ki a többiek közül (0,0155), míg az RNN-GRU bizonyult a leggyengébbnek (0,0235). A Nikkei225-ön végzett árfolyambecslések eredményei a MAPE mutatók tekintetében a 0,0113 és a 0,0205 közötti intervallumba estek. Előbbit egy hibrid modellel az LSTM-GRU-val, míg utóbbit a hagyományos GRU-val sikerült elérni.


A többváltozós modellezés során a MAPE értékek az S&P500-nál minimálisan tudtak még javulni. A leghatékonyabbnak az RNN-GRU (0,0140), a legrosszabbnak pedig az LSTM bizonyult (0,0174). A DAX indexnél is tapasztalható volt előrelépés a további magyarázó változók bevonása révén, melynek hatására a GRU teljesítménye a korábbi 0,0155-ről 0,0154-re módosult. A legkevésbé használhatónak az RNN-GRU bizonyult (0,0326). A Nikkei225 tőzsdeindexnél a legpontosabbnak az LSTM-GRU hibrid (0,0111), míg a legpontatlanabbnak az RNN modell tekinthető (0,0294). Összességében nem lehet egyértelműen kijelenteni, hogy a többváltozós módszerek alkalmazása jelentősen javítani tudott volna a prediktív teljesítményen.



31. ábra: A részvénytőzsi előrejelzések MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

A 32. ábra a három vizsgált időszak részvénypiacokra vonatkozó átlagos becslési pontosságát mutatja az alkalmazott modellek szerinti bontásban. Az eredmények alapján elmondható, hogy a nyugalmi állapot, azaz a 2018. első féléves részvényindex előrejelzések voltak a legpontosabbak. Ezek közül kiemelkedik a többváltozós GRU algoritmus, ami összességében a legjobb előrejelzéseket szállította, ellenben az RNN-GRU hibrid módszerrel, amely a leggyengébben szerepelt. A Covid19 felfutásának idején, 2020-ban tapasztalhatók a leginkább szélsőséges értékek, ami a modellek megbízhatóságát is jelentősen próbára tette. Ebben az időszakban ugyanis rendkívül magas volatilitás jellemezte a részvénypiacokat. A lezárások, a védekezés és a bizonytalanság mind meghatározó szerepet játszottak az árfolyamok alakulásában. Ugyanakkor a GRU módszer ekkor is sikeresen vette az akadályt, ellenben az RNN-nel és RNN-LSTM-mel szemben, amelyek meglehetősen pontatlannak bizonyultak. Nagyjából a két előbb említett időszak közé pozícionálható a 2022-es, ami az átlagos MAPE értékek alapján való megítélést illeti. A prediktív teljesítményt tekintve annyira nem szélsőséges, mint a Covid19-es periódus, de a teljesítményen látszik, hogy egy krízissel sújtott korszakot vizsgáltam. A legmegbízhatóbb a többváltozós LSTM-GRU hibrid modell lett, míg a legkevésbé használható előrejelzést az RNN algoritmus produkálta.




32. ábra: A részvénypiaci előrejelzések MAPE mutatóinak átlaga a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018., 2020. és 2022.)

Forrás: saját szerkesztés

5.1.2. Árupiac

Az árupiacok elemzése során szintén három terméket vizsgáltam. A nyersolajat, az aranyat és az ezüstöt, amelyeket a szakirodalomban is gyakran alkalmaznak. A 33. ábrán az említett eszközök 2018. első félévére vonatkozó előrejelzéseinek MAPE értékei láthatók. Az egyváltozós modellezés során a nyersolaj esetében a legpontosabb teljesítményt a GRU érte el 0,0160-as értékkel, melytől az RNN csak minimálisan maradt el (0,0164). A legpontatlanabb pedig az RNN-GRU hibrid volt (0,0321). Az arany árfolyamát vizsgálva azt tapasztaltam, hogy itt az RNN algoritmus bizonyult a legjobb választásnak (0,0054), míg az RNN-LSTM teljesített a leggyengébben (0,0143). Az ezüst árfolyamalakulásán végzett predikciók eredményei a MAPE mutatók tekintetében a 0,0091 és a 0,0127 között mozogtak. Előbbit az RNN-LSTM, míg utóbbit az LSTM-GRU modell futtatása eredményezte.

A többváltozós elemzések esetében csak az olaj esetében volt tapasztalható némi javulás a MAPE értékeket figyelembe véve. Ezesetben az RNN-LSTM a legjobb (0,0136), míg a sima RNN a legrosszabb eredményt mutatta (0,0240). Az aranyánál nem figyelhető meg előrelépés az átlagos abszolút százalékos hiba tekintetében. A legjobb teljesítményt ezúttal az LSTM-GRU érte el 0,0065-tel, a legrosszabbat pedig az RNN (0,0104). Az ezüstenél a GRU lett a legmegbízhatóbb a 0,0091-es MAPE-val. A legpontatlanabbnak pedig az LSTM-GRU hibrid modell mutatkozott (0,0143). Összességében elmondható, hogy a 2018-as időszakra vonatkozó előrejelzésekben a nyersolaj árfolyama volt a legnehezebben megbecsülhető, míg az arany mutatta a legnagyobb stabilitást ilyen téren. Az olaj és az ezüst esetében a többváltozós modellek tovább tudtak javítani a legjobb becslési pontosságon.




33. ábra: Az áruipiaci előrejelzések MAPE mutatói nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A Covid jelentős volatilitást okozott az áruipacokon, különösen igaz ez a nyersolajra, ami az előrejelzéshez használt modellek teljesítményét is hatalmas mértékben befolyásolta a 2020-as évben (34. ábra). Az egyváltozós vizsgálatok során a nyersolajnál figyelhető meg a leginkább instabil teljesítmény. Meglehetősen szélsőséges eredmények születtek, azonban a GRU modell még ennek ellenére is 0,0845-tel képes volt a legjobb értéket produkálni, míg a legrosszabb az RNN-nek tulajdonítható (0,1770). Ezen időszakban az arany tekinthető a legstabilabbnak, amelynél szintén a GRU algoritmus érte el a legnagyobb becslési pontosságot 0,0118-cal. Az RNN-LSTM pedig a 0,0420-es értékkel a leggyengébb eredményt hozta. Az ezüst esetében a legalacsonyabb MAPE mutatót az RNN és a GRU (0,0203), a legmagasabbat pedig az RNN-GRU (0,0304) predikciói eredményezték. Jól látszik, hogy az utóbbi két termék esetében jóval kisebb volt a különbség a legjobb és a legrosszabb MAPE értékek között, mely főként az alacsonyabb volatilitásra és stabil árfolyampályára vezethető vissza.

A többváltozós modellek alkalmazása során a nyersolaj esetében is a GRU modell (0,0817) bizonyult a leghatékonyabbnak, míg az RNN-LSTM produkálta a leggyengébb teljesítményt 0,2935-tel, ami rendkívül szélsőségesnek tekinthető. Az arany árfolyamelemzésénél megint csak a GRU modell tekinthető a legpontosabbnak az általa elért 0,0115-ös értékkel. Az eredmények alátámasztják, hogy a legpontatlanabb pedig az RNN-LSTM algoritmus lett (0,0485). A hagyományos GRU a 0,0219-es teljesítménnyel a legoptimálisabb modellválasztásnak bizonyult az ezüst 2020. első féléves előrejelzései szempontjából. A legmegbízhatatlanabbnak pedig az RNN

bizonyult 0,0334-es értékkel. Ki kell emelnem továbbá, hogy a többváltozós módszerek alkalmazásával a nyersolaj és az ezüst becslési pontosságát tovább sikerült javítani.




34. ábra: Az áruipiaci előrejelzések MAPE mutatói a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés

A 2022. első félévére vonatkozó előrejelzések eredményeit a 35. ábra tartalmazza. Ez az időszak nagyjából a nyugalmi és az orosz-ukrán háború közé pozicionálható, ami a MAPE értékek alakulását illeti. Az egyváltozós predikciók során a legpontosabb prediktív teljesítményt a nyersolaj esetében a GRU érte el 0,0269-es MAPE-val. A legpontatlanabbnak az RNN-LSTM bizonyult (0,0632). Az arany árfolyamának modellezése során azt tapasztaltam, hogy három modell is nagyon hasonló eredményeket produkált, de az LSTM-GRU algoritmus minimális előnnyel végzett az első helyen (0,0086), míg a GRU bizonyult a leggyengébbnek (0,0131). Az ezüsten végzett árfolyambecslések eredményei a MAPE mutatók tekintetében a 0,0145 és a 0,0172 közötti meglehetősen szűk intervallumba estek. Előbbit az LSTM-mel, míg utóbbit a hibrid RNN-GRU-val sikerült elérni.

A többváltozós modellezést követően a MAPE értékek a nyersolajnál a következőképpen alakultak. A leghatékonyabb a GRU (0,0269) volt, ami megegyezik az egyváltozós becslés legjobb eredményével. A legrosszabb becslési pontosságot pedig az RNN-LSTM adta (0,0721). Az aranyánál tapasztaltam előrelépést a további magyarázó változók bevonása révén, melynek hatására az LSTM teljesítménye a 0,0077-es szintet érte el. A legkevésbé használhatónak az LSTM-GRU bizonyult (0,0111). Az ezüstenél a legpontosabbnak a GRU (0,0145), míg a legpontatlanabbnak az


RNN-LSTM modell tekinthető (0,0244). Összességében nem lehet egyértelműen kijelenteni, hogy a többváltozós módszerek alkalmazása jelentősen javítani tudott volna a prediktív teljesítményen, ugyanis csak az arany esetében látható némi pozitív irányú változás.



35. ábra: Az árupiaci előrejelzések MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

A 36. ábra a vizsgált időszakok árupiacokra vonatkozó átlagos becslési pontosságát mutatja az alkalmazott modellek szerinti bontásban. Az eredmények alapján elmondható, hogy a nyugalmi állapot, azaz a 2018. első féléves előrejelzések voltak a legpontosabbak. Ezek közül kiemelkedik a többváltozós GRU, ami összességében a legjobb előrejelzéseket adta, ellenben az RNN-LSTM hibrid módszerrel, amely a leggyengébben szerepelt. A Covid felfutásának idején, 2020-ban tapasztalható a legszélsőségesebb értékek, hasonlóan a részvénytőzsi vizsgálatokhoz. Ebben az időszakban ugyanis magas volatilitás jellemezte az árupiacokat. Kifejezetten igaz volt ez az olajipari termékekre és a lezárásokból adódó keresletcsökkenésre. A GRU módszer ebben az esetben is stabil teljesítményt mutatott, ellenben az RNN-LSTM-mel szemben, ami összességében a legrosszabb választásnak bizonyult. Az árupiacok esetében is igaz az, hogy a 2022-es időszak átlagos MAPE értékei nagyjából a kontroll és a háborús periódusban generált becslési teljesítmény közé esnek. A legmegbízhatóbb a többváltozós GRU modell lett, míg a legkevésbé használható előrejelzéseket az RNN-LSTM algoritmus produkálta.



36. ábra: A áruipiaci előrejelzések MAPE mutatóinak átlaga a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018., 2020. és 2022.)


Forrás: saját szerkesztés

5.1.3. Kriptovaluta piac

A kriptovaluták közül a Bitcoin, az Ethereum és a Litecoin került be a vizsgálati adatbázisba, amelyek együttesen a teljes piaci kapitalizáció kb. 71,68%-át teszik ki (www.coinmarketcap.com, 2024. május). A 37. ábra a 2018. első félévére vonatkozó előrejelzéseinek MAPE értékeit tartalmazza. Az egyváltozós modellezés során a legpontosabb prediktív teljesítményt Bitcoin-nál a GRU érte el 0,0457-tel. A legpontatlanabb pedig az RNN volt (0,1771). Az Ethereum árfolyamát vizsgálva azt tapasztaltam, hogy az RNN-GRU algoritmus adta a legoptimálisabb eredményt (0,0586), míg az RNN-LSTM bizonyult a leggyengébbnek (0,1015). A Litecoin-nal végzett predikciók jelentették a legnagyobb kihívást, amelynek eredményei a MAPE mutatók tekintetében a 0,1130 és a 0,3389 között mozogtak. Előbbit a legegyszerűbb modell az RNN, míg utóbbit egy vegyes módszertan az RNN-GRU produkálta.

A többváltozós modellezés esetében tovább javult a hatékonyság, ami a MAPE értékekben is megmutatkozik. A Bitcoin-nál a legjobbnak itt is a GRU (0,0448) bizonyult, míg a legrosszabb teljesítményt az RNN mutatta (0,0989). Az Ethereumnál is tapasztalható volt előrelépés egészen a 0,0570-ás szintig javult az előrejelzési teljesítmény, melyet az RNN és az RNN-GRU módszerekkel sikerült elérni. Az utolsó helyet ezúttal az LSTM modell szerezte meg 0,0994-gyel, ami szintén javulásnak számít az egyváltozós becsléshez képest. A Litecoin-nál a GRU algoritmus tudta legoptimálisabb becslést generálni (0,1006). A legpontatlanabb pedig az RNN-LSTM hibrid

lett (0,2907). Összességében elmondható tehát, hogy a kriptovaluták vizsgálata során a többváltozós algoritmusok alkalmazása javítani tudta a teljesítményt a 2018. első félévére vonatkozó előrejelzési periódusra vonatkozóan.




37. ábra: A kriptovaluta előrejelzések MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A kriptovaluta szektort érintették legkevésbé a Covid terjedésével kapcsolatos problémák, amely a vizsgálati eredményeken is jól látható (38. ábra). Az egyváltozós vizsgálatok során a Bitcoin esetében a legjobb prediktív teljesítményt a GRU (0,0301), míg a legrosszabbat az RNN (0,0411) érte el. Az Ethereum-nál az LSTM teljesített a legmeggyőzőbben 0,0364-es hibaértékkel, míg az RNN a legrosszabb becslési pontossággal az utolsó lett (0,0547). A Litecoin esetében a legalacsonyabb MAPE mutatót az LSTM (0,0342), a legmagasabbat pedig a GRU (0,0533) érte el.

A többváltozós modellek alkalmazásával a Bitcoin esetében a GRU modell (0,0276) bizonyult a leghatékonyabbnak, de az LSTM sem sokkal maradt el tőle (0,0279). Az RNN produkálta viszont a leggyengébb teljesítményt 0,0473-mal. Az Ethereum-nál a vizsgált módszerek tekintetében az LSTM-GRU dolgozott a legkisebb hibaértékkel (0,0367), de nem sikerült felülmúlni az egyváltozós becslés abszolút legjobb teljesítményét. Az eredmények alapján a legpontatlanabb az RNN algoritmus lett (0,0496). Az LSTM-GRU hibrid a legoptimálisabb a Litecoin 2020. első féléves előrejelzései szempontjából 0,0336-os MAPE értékkel. A legmegbízhatatlanabbnak pedig az RNN-GRU bizonyult rendkívül kiugró 0,0835-ös mutatóval. Fontos kiemelni, hogy az

Ethereum kivételével csökkent a MAPE értékek alsó intervallum határa, ami arra utal, hogy abszolút teljesítményben a többváltozós modellek alkalmazása előrelépést jelent az egyváltozósakhoz képest.




38. ábra: A kriptovaluta előrejelzések MAPE mutatói a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés

A harmadik előrejelzési időszakban, azaz 2022. első félévében (39. ábra) az egyváltozós predikciók során a legpontosabb prediktív teljesítményt a Bitcoin esetében a GRU érte el 0,0274-es MAPE értékkel, melytől az RNN-LSTM jóval gyengébbnek bizonyult (0,0608). Az Ethereum árfolyamának modellezése esetén azt tapasztaltam, hogy itt is a GRU algoritmus emelkedett ki a többiek közül (0,0357), míg az RNN-LSTM bizonyult a leggyengébbnek (0,0614). A Litecoin-nal végzett árfolyambebecslések eredményei a MAPE mutatók tekintetében a 0,0367 és a 0,0644 közötti intervallumba estek. Előbbit az LSTM-mel, míg utóbbit a hagyományos az RNN-nel sikerült elérni.

A többváltozós modellezés során a leghatékonyabbnak az LSTM-GRU (0,0284), a legrosszabbnak pedig az RNN-LSTM bizonyult (0,0441). Az Ethereum-nál sem volt tapasztalható további előrelépés több magyarázó változó bevonásával. A LSTM teljesítménye lett a legjobb (0,0433), minimálisan megelőzve az LSTM-GRU-t (0,0438). A legkevésbé használhatónak az RNN-GRU bizonyult (0,0468). Bár látható, hogy ebben az esetben az intervallum alsó és felső határa között minimális eltérés mutatkozott. A Litecoin kriptovalutánál a legpontosabbnak az LSTM (0,0418),


míg a legpontatlanabbnak a GRU modell tekinthető (0,0653) Összességében elmondható, hogy a többváltozós módszerek alkalmazása nem volt képes javítani a prediktív teljesítményen.



39. ábra: A kriptovaluta előrejelzések MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

A 40. ábra a három időszak kriptovalutákra vonatkozó átlagos becslési pontosságát mutatja az alkalmazott modellek szerinti bontásban. Az eredmények alapján megállapítható, hogy ami alapvetően nyugalmi állapotot kellene, hogy jelentsen (2018.) a kripto piacon különösen szélsőséges eredményeket hozott és ez a periódus tekinthető a legproblémásabbnak, ami a modellek megbízhatóságát is jelentősen próbára tette. Ugyanakkor az összes vizsgált módszer közül kiemelkedik a többváltozós GRU algoritmus, ami összességében a legjobb előrejelzéseket szállította, ellenben az RNN-GRU egyváltozós hibrid módszerrel, amely ugyanakkor a leggyengébben szerepelt. A Covid felfutásának idején, 2020-ban tapasztalhatók a legkiegyensúlyozotabb MAPE értékek. A többi vizsgált piaccal ellentétben a kriptovalutákra ebben az időszakban a kevésbé magas volatilitás volt jellemző. Az átlagos értékek tekintetében az LSTM módszer volt a legsikeresebb, szemben az RNN-GRU-val. A 2022-es időszak átlagos eredményei a prediktív teljesítményt tekintve annyira nem szélsőséges, mint 2018-ban. A legmegbízhatóbb az egyváltozós GRU modell lett, míg a legkevésbé használható előrejelzést a szintén egy magyarázóváltozóval rendelkező RNN-LSTM hibrid algoritmus produkálta.




40. ábra: A kriptovaluta előrejelzések MAPE mutatóinak átlaga a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018., 2020. és 2022.)

Forrás: saját szerkesztés

5.1.4. Devizapiac

A devizapiaci elemzésbe az EUR/USD, a GBP/USD és az AUD/USD került bevonásra. A 2018. első félévére vonatkozó előrejelzések MAPE értékeit a 41. ábra szemlélteti. Az egyváltozós modellezés során a legpontosabb prediktív teljesítményt az EUR/USD esetében a GRU érte el 0,0041-es értékkel. A legpontatlanabb pedig a RNN volt (0,0124). A GBP/USD devizakereszt árfolyamát vizsgálva azt tapasztaltam, hogy itt is GRU algoritmus emelkedett ki a (0,0039), míg az RNN-LSTM és az LSTM a leggyengébbek (0,0051). Az AUD/USD-vel végzett predikciók eredményei a MAPE mutatók tekintetében a 0,0044 és a 0,0068 között mozogtak. Előbbit a GRU, míg utóbbit a hibrid LSTM-GRU-val sikerült elérni.

A többváltozós modellezéssel még pontosabbak lettek a modellek, amely MAPE értékekben is megmutatkozik. Az EUR/USD-nál tovább javult a hatékonyság, a legjobbnak a GRU (0,0025), a legrosszabbnak meglepetésre az RNN-LSTM bizonyult (0,0096). A GBP/USD-nél is tapasztalható volt előrelépés az egyváltozós eredményhez képest, ugyanis egészen a 0,0025-ös szintig sikerült optimalizálni a modellbecslést a GRU módszer segítségével. Az utolsó helyet ezúttal is az RNN-LSTM modell szerezte meg 0,0078-cal, ami szintén javulásnak számít az egyváltozós becsléshez képest. Az AUD/USD-nél a legpontosabb a GRU (0,0029), a legpontatlanabb pedig az RNN-GRU hibrid lett (0,0048). Összességében elmondható, hogy a vizsgált időszakban a többváltozós algoritmusok alkalmazása tovább tudott javítani a prediktív teljesítményen.




41. ábra: A devizapiaci előrejelzések MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A vizsgálatba bevont devizapiackeresztek volatilitása jóval kisebb mértékű, mint a korábban ismertetett részvény-, áru- vagy kriptovaluta piaci termékeké, de a Covid-járvány terjedésének hatásai ebben az esetben is érezhetőek voltak, ami az előrejelzéshez használt modellek teljesítményét is befolyásolta (42. ábra). Az egyváltozós vizsgálatok során az EUR/USD-nél figyelhető meg a leginkább stabil teljesítmény. Ebben az esetben a legjobb (LSTM 0,0049) és a legrosszabb (RNN-GRU 0,0079) prediktív teljesítmény között sem tapasztalható jelentős eltérés. A GBP/USD vizsgálata során a legjobb eredménnyel a GRU algoritmus volt képes dolgozni, mely 0,0062-es MAPE értéket ért el. Ezzel szemben az RNN-LSTM 0,0087-es becslési pontosságot mutatott. Az AUD/USD számít a legproblémásabbnak ebben az időszakban, melynek esetében a legalacsonyabb MAPE mutatót a GRU (0,0098), a legmagasabbat pedig az RNN-GRU (0,0165) érte el.

A többváltozós modellek alkalmazásával az EUR/USD esetében az LSTM modell (0,0025) bizonyult a leghatékonyabbnak, míg az RNN-LSTM produkálta a leggyengébb teljesítményt 0,0062-vel. A GBP/USD esetében a legjobb eredményt az LSTM és az LSTM-GRU érte el 0,0034-gyel. Az eredmények alátámasztják, hogy a legpontatlanabb az RNN-LSTM algoritmus lett (0,0071). A hagyományos GRU a 0,0060-as teljesítményével a legoptimálisabb modellnek tekinthető az AUD/USD 2020. első féléves előrejelzései szempontjából. A legmegbízhatatlanabb pedig az RNN lett 0,0191-es értékkel. Fontos megemlíteni, hogy a többváltozós modellek

alkalmazása ebben a vizsgálati időszakban is további előrelépést jelentett a legjobb MAPE értékek alakulása szempontjából.




42. ábra: A devizapiaci előrejelzések MAPE mutatói a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés

A 2022. első félévére vonatkozó előrejelzések MAPE értékeit a 43. ábra tartalmazza. Az egyváltozós predikciók során a legpontosabb prediktív teljesítményt az EUR/USD esetében az LSTM érte el 0,0057-es MAPE mutatóval. A legpontatlanabbnak pedig az RNN-LSTM bizonyult (0,0125). A GBP/USD árfolyamának modellezése során azt tapasztaltam, hogy a GRU algoritmus tekinthető a legjobbnak (0,0043), míg az RNN-LSTM a leggyengébbnek (0,0098). Az AUD/USD-on végzett kísérletek eredményei a MAPE mutatók tekintetében a 0,0059 és a 0,0090 közötti intervallumba estek. Előbbit az LSTM és a GRU, míg utóbbit az RNN-nel sikerült elérni.


A többváltozós modellezés során a MAPE értékek esetében további javulás figyelhető meg. Az EUR/USD-nál a leghatékonyabbnak a GRU (0,0024), a legrosszabbnak pedig az RNN-LSTM bizonyult (0,0091). A GBP/USD devizapárnál is tapasztalható volt előrelépés a további magyarázó változók bevonása révén, melynek hatására az LSTM teljesítménye a 0,0026-os hibaértéket volt képes elérni. A legkevésbé használhatónak az RNN bizonyult (0,0089). Az AUD/USD devizakeresznél a legpontosabbnak a GRU (0,0039), míg a legpontatlanabbnak az LSTM modell tekinthető (0,0064). A többváltozós módszerek alkalmazása ebben az esetben is hozzájárult a prediktív teljesítmény javulásához.



43. ábra: A devizapiaci előrejelzések MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

A 44. ábra a három vizsgált időszak devizapiaci termékeire vonatkozó átlagos becslési pontosságát mutatja az alkalmazott modellek szerinti bontásban. Az eredmények alapján elmondható, hogy a nyugalmi állapot, azaz a 2018. első féléves részvényindex előrejelzések voltak a legpontosabbak. Ezek közül kiemelkedik a többváltozós GRU algoritmus, ami összességében a legjobb előrejelzéseket szállította, ellenben az RNN módszerrel, amely a leggyengébben szerepelt. A Covid felfutásának idején, 2020-ban tapasztalhatók a legszélsőségesebb értékek, ami a modellek megbízhatóságát is jelentősen próbára tette. Ugyanakkor a többváltozós GRU módszer ekkor is sikeresen vette az akadályt, ellenben az RNN-nel szemben, amelyek meglehetősen pontatlannak bizonyultak. A 2022-es időszak nagyjából a két korábbi közé pozicionálható, ami az átlagos MAPE értékek alapján való megítélést illeti. A prediktív teljesítményt tekintve annyira nem szélsőséges, mint a Covid periódus. A legmegbízhatóbb ebben az esetben is a többváltozós GRU modell lett, míg a legkevésbé használható előrejelzést az RNN-LSTM hibrid algoritmus produkálta.




44. ábra: A devizapiaci előrejelzések MAPE mutatóinak a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018., 2020. és 2022.)

Forrás: saját szerkesztés

5.2. Termékek közötti összehasonlítás


A termékek közötti összehasonlítást a 2018-as előrejelzési időablakra vonatkozóan a 45. és a 46. ábra mutatja be. A legkönnyebben a devizakereszték árfolyamait sikerült modellezni, mivel ezek esetében a legkisebb a volatilitás. Ezzel szemben a kriptovalutáknál mért MAPE értékek jóval szélsőségesebb skálán mozogtak és az egyes algoritmusok között jelentős különbségeket tapasztaltam. Az árupiaci termékek közül az arany és ezüst árfolyamalakulását sikerült a legoptimálisabban megbecsülni, míg a nyersolaj tűnik a leginkább kirívó esetnek. A részvényindexek szintén stabil teljesítményt mutattak a prediktív elemzések során. Azt a következtetést is levonhatjuk, hogy a többváltozós modellek futtatása tovább tudta javítani a módszerek becslési pontosságát.



45. ábra: A vizsgált termékek egyváltozós modelljeinek MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés


EUR/USD Az egyik legnagyobb eltéréseket mutató eszköz. Az egyváltozós esetben (45. ábra) a RNN-GRU kombináció extrém kiugrása figyelhető meg, míg a többváltozós becslési eredményeknél (46. ábra) az RNN-LSTM dominál. A GBP/USD és AUD/USD mindkét vizsgálatnál relatíve alacsony értékeket mutatnak, és a különböző modellek között nincs jelentős eltérés. A nyersolaj esetében az egyváltozós vizsgálatoknál (45. ábrán) a különbségek markánsabbak, különösen az RNN és GRU modellek esetében. Az arany és ezüst esetében a különbségek minimálisak és a modellek hasonló teljesítményt nyújtanak mindkét vizsgálat típus esetén.



46. ábra: A vizsgált termékek többváltozós modelljeinek MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés


A 2020-as időszakra vonatkozó összehasonlítást a 47. és a 48. ábra szemlélteti. Jól látható, hogy a nyugalmi időszakhoz képest ezekben az esetekben jelentős korrekció következett be a modellezési pontosságot illetően. A legkönnyebben itt is a devizakereszték árfolyamait sikerült megbecsülni. Azonban a Covid okozta sokknak köszönhetően a legnehezebben előrejelezhető termék a nyersolaj volt, amelynek határidős árfolyama egy ideig negatív tartományban is tartózkodott. Az ilyen szélsőséges mozgásokat a tanuló és a tesztelő adatbázis tekintetében is meglehetősen nehezen tudják kezelni még a legösszetettebb mély tanulási algoritmusok is.



47. ábra: A vizsgált termékek egyváltozós modelljeinek MAPE mutatói a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés


Érdekesség, hogy a korábbi időszakhoz képest a kriptovaluták MAPE értékei jelentősen csökkentek és nagyjából az 5,5%-os felső hibahatárt célozták meg. A részvényindexek esetén szintén jelentősen megugrott a becslési pontatlanság mértéke, melyhez a piaci bizonytalanság is hozzájárult.



48. ábra: A vizsgált termékek többváltozós modelljeinek MAPE mutatói a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés


A 2022-es időszak az orosz-ukrán konfliktus prediktív modellezésre hatással volt, ami a nyugalmi periódushoz viszonyított teljesítményeket illeti (49. és 50. ábra). Nem látható változás abban a tekintetben, hogy a devizakereszték árfolyamelőrejelzései mutatják továbbra is a legnagyobb stabilitást. Hasonlóan konzekvens eredmények látszanak az arany esetében. A nyersolajnál ismételten nehézségeket tapasztaltam, amely az energiapiacokon uralkodó bizonytalanságnak köszönhető, bár nem tekinthető olyan szélsőségesnek a MAPE értékek alakulása, mint a pandémia idején. A kriptovaluták esetében is visszaköszön a volatilitásukból adódó becslési pontosság csökkenés, ugyanakkor az is látható, hogy a tanulási minták jobb alapot szolgáltatnak, mint a 2018-as előrejelzések esetében. A részvényindexeknél megfigyelhető, hogy ez is egy gazdaságilag stresszes periódus, amelyben a prediktív modellek teljesítménye csökken.



49. ábra: A vizsgált termékek egyváltozós modelljeinek MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

Az összetettebb modellek (LSTM, GRU és ezek kombinációi) bizonyos eszközök esetében jobban teljesítenek, de nincs egyértelműen domináns modell. A stabilabb termékekénél (pl. devizapárok) a modellek teljesítménye közelebb áll egymáshoz, ami azt sugallja, hogy ezeknél az eszközöknél nincs szükség túlságosan komplex módszerekre és a devizapiaci előrejelzések tekintetében egyik modell sem emelkedik ki jelentősen az adott időszakban. Az olajárak esetében gyakran előfordulnak hirtelen változások, például geopolitikai események vagy kereslet-kínálati sokkok miatt. Az LSTM-GRU és GRU modellek általában jók az időbeli mintázatok kezelésére, mégis itt az RNN és az RNN-LSTM szerepel a legjobban (50. ábra).




50. ábra: A vizsgált termékek többváltozós modelljeinek MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

5.3. Modellenkénti összteljesítmény összehasonlítás

Megvizsgáltam az alkalmazott modellek minden termékre vonatkozó összteljesítmény alakulását is a MAPE értékek viszonylatában, melynek ábrázolásához dobozdiagramokat (boxplot) használtam. Ezek sajátossága, hogy egy ábrán lehet bemutatni az interkvartilis terjedelmet (téglalap zárt része, ahova a vizsgált értékek 50%-a esik), a mediánt (vízszintes vonal a téglalapon belül), az átlagot (x jelzés), a legmagasabb és legalacsonyabb, valamint a kiugró (outlier) értékeket (pontok).


A 51. ábrán a 2018. év első félévére vonatkozó egyváltozós előrejelzések MAPE értékei szerepelnek. A modellek teljes termékskálára vetített eredményei szerinti bontásban. A legkisebb interkvartilis terjedelem a GRU esetében mutatkozik, amely esetében a maximum érték 7% alatt található, illetve a legkisebb MAPE mutató is ennél a modellnél figyelhető meg. Mindegyik módszertannál a medián érték a doboz alsó részén található, amely az adatok eloszlásában pozitív ferdeséget feltételez. A kiugró érték alakulása szerint az RNN-GRU módszer tűnik a legszélsőségesebbnek. Ennél a vizsgálati időszaknál nem mutatkoznak meg a hibrid modellek előnyei az összteljesítmény értékelésénél.



51. ábra: Az alkalmazott egyváltozós modellek össztermékszintű MAPE mutatóinak alakulása a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés


A 52. ábrán a 2018. év első felévére vonatkozó többváltozós előrejelzések MAPE értékei szerepelnek. Ebben az esetben is megállapítható, hogy a legkonzisztensebb teljesítményt a GRU modell nyújtotta, melytől a legnagyobb becslési pontosság tekintetében az LSTM ugyan csak minimálisan maradt el, de az összteljesítmény tükrében már árnyaltabb a kép. Az korábbihoz hasonlóan ezen az ábrán is látható, hogy mindegyik modellnél a medián érték a doboz alsó részén található, amely alapján az adatok eloszlásában pozitív ferdeség fedezhető fel. A legnagyobb kiugró érték az RNN-LSTM algoritmushoz köthető. Ebben a vizsgált periódusban a modellek teljesítményére leginkább a kriptovaluták rendkívül magas volatilitása hatott, ami az összteljesítményt is jelentősen rontotta.



52. ábra: Az alkalmazott többváltozós modellek össztermékszintű MAPE mutatóinak alakulása a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés


A 53. ábrán a 2020. év első félévére vonatkozó egyváltozós előrejelzések MAPE értékei szerepelnek. A legkisebb interkvartilis terjedelem az LSTM-nél tapasztalható, amely esetében a maximum érték 3,65% alatt található, illetve a legkisebb MAPE mutató is ennél a modelnél figyelhető meg (0,49%). Az eloszlások tekintetében kicsit más a helyzet, mint a korábbi időszakban, ugyanis az LSTM esetében a medián érték a doboz középső részén található, amely az adatok szempontjából normáeloszlást feltételez és a többi algoritmusnál is megfigyelhető az elmozdulás a pozitív ferdeségű függvényből. A kiugró érték alakulása szerint az RNN módszer tűnik a legkirívóbbnak.



53. ábra: Az alkalmazott egyváltozós modellek össztermékszintű MAPE mutatóinak alakulása a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés


Az 54. ábrán pedig a 2020. év első felévére vonatkozó többváltozós előrejelzések MAPE értékei szerepelnek. Ebben az esetben megállapítható, hogy a legkonzisztensebb teljesítményt az LSTM és az LSTM-GRU modellek nyújtották. A medián értékek tekintetében itt már meglehetősen vegyes a kép, ugyanis normáeloszlás, a pozitív és negatív ferdeségű eloszlásfüggvényeket is fel tudunk fedezni. A legnagyobb kiugró érték az RNN-LSTM algoritmushoz köthető. Ebben a vizsgált periódusban a modellek teljesítményére leginkább a nyersolaj árának volatilitása volt hatással, de jóval kisebb mértékű torzítást eredményezett, mint a korábbi időszakban a kriptovaluták által okozott hatás.



54. ábra: Az alkalmazott többváltozós modellek össztermékszintű MAPE mutatóinak alakulása a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés


Az 55. ábra a 2022. év első felévére vonatkozó egyváltozós előrejelzések MAPE értékeit mutatja, a modellek teljes termékskálára vetített eredményei szerinti bontásban. A legkisebb interkvartilis terjedelem a GRU esetében mutatkozik, ahogy az a 2018-as időszakban is megfigyelhető volt. Mindegyik modellnél a medián érték a doboz alsó részén található, amely az adatok eloszlásában pozitív ferdeséget feltételez. A kiugró értékek nem láthatók az ábrán. Ez többek között azzal is magyarázható, hogy a vizsgált termékek volatilitása nem volt olyan magas, mint a korábbi időszakokban, illetve a modellek tanulási adatbázisa is jelentősen megváltozott.



55. ábra: Az alkalmazott egyváltozós modellek össztermékszintű MAPE mutatóinak alakulása az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

Az 56. ábrán pedig a 2022. év első felévére vonatkozó többváltozós előrejelzések MAPE értékei szerepelnek. Ebben az esetben megállapítható, hogy a legkonzisztensebb teljesítményt az LSTM-GRU modell nyújtotta. Ugyanakkor a GRU abszolút legjobb becslési pontosságát nem sikerült elérni. A medián értékek tekintetében az egyváltozós modellezéshez hasonlóan a pozitív ferdeségű eloszlásfüggvények a jellemzőek, tehát a doboz alsó részén helyezkednek el. A kiugró értékek nem láthatók az ábrán. Ez többek között azzal is magyarázható, hogy a vizsgált termékek volatilitása nem volt olyan magas, mint a korábbi időszakokban, illetve a modellek tanulási adatbázisában szereplő adatok sem voltak olyan szélsőségesek.



56. ábra: Az alkalmazott többváltozós modellek össztermékszintű MAPE mutatóinak alakulása az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

5.4. Abszolút legjobb és legrosszabb eredmények

A továbbiakban az eredmények összefoglaló tábláit ismertetem.

A 11. táblázat (2. függelék) a 2018. féléves előrejelzésére vonatkozó egyváltozós modellek MAPE mutatóit tartalmazza. Megállapítható, hogy a legkisebb és ezáltal a legpontosabb becslést a GRU modell volt képes produkálni a GBP/USD devizapár esetében 0,0039-es értékkel. Míg a legrosszabb prediktív teljesítmény (0,3389) az egyik hibrid módszerhez (RNN-GRU) köthető, amelyet a Litecoin vizsgálat során tapasztaltam.

11. táblázat: A 2018. január 1. és 2018. június 30. közötti időszak egyváltozós módszerrel becsült MAPE mutatók

2018	Egyváltozós						
Termékek	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU	Átlag
S&P500	0,0130	0,0080	0,0150	0,0080	0,0138	0,0083	0,0110
DAX	0,0109	0,0109	0,0089	0,0125	0,0098	0,0138	0,0111
Nikkei225	0,0082	0,0181	0,0095	0,0086	0,0095	0,0250	0,0132
Nyersolaj	0,0164	0,0190	0,0160	0,0234	0,0269	0,0321	0,0223
Arany	0,0054	0,0096	0,0068	0,0088	0,0143	0,0059	0,0085
Ezüst	0,0113	0,0099	0,0109	0,0127	0,0091	0,0104	0,0107
Bitcoin	0,1771	0,1101	0,0457	0,1107	0,0625	0,1002	0,1011
Ethereum	0,0674	0,0626	0,0692	0,0620	0,1015	0,0586	0,0702
Litecoin	0,1130	0,1912	0,1906	0,2490	0,1168	0,3389	0,1999
EUR/USD	0,0124	0,0062	0,0041	0,0085	0,0072	0,0068	0,0075
GBP/USD	0,0050	0,0051	0,0039	0,0043	0,0051	0,0046	0,0047
AUD/USD	0,0048	0,0059	0,0044	0,0068	0,0063	0,0046	0,0055
Átlag	0,0371	0,0381	0,0321	0,0429	0,0319	0,0508	

Forrás: saját szerkesztés

Az 12. táblázatban (3. függelék) a 2018. féléves előrejelzésére vonatkozó többváltozós modellek MAPE értékei találhatók. Ennél a vizsgálati módszernél a legpontosabb prediktív teljesítményt is a GRU modell produkálta szintén egy devizapár az EUR/USD esetében 0,0025-tel. A leggyengébben az RNN-LSTM hibrid algoritmus teljesített (0,2907). Ha az abszolút legjobb és legrosszabb teljesítményt nézzük, akkor elmondható, hogy összességében a többváltozós modellváltozatok működtek jobban a 2018-as előrejelzési időtávon.

12. táblázat: A 2018. január 1. és 2018. június 30. közötti időszak többváltozós módszerrel becsült MAPE mutatók

2018	Többváltozós						
Termékek	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU	Átlag
S&P500	0,0094	0,0129	0,0078	0,0085	0,0104	0,0095	0,0098
DAX	0,0092	0,0090	0,0087	0,0137	0,0107	0,0125	0,0106
Nikkei225	0,0090	0,0083	0,0096	0,0083	0,0131	0,0083	0,0094
Nyersolaj	0,0240	0,0229	0,0138	0,0191	0,0136	0,0150	0,0181
Arany	0,0104	0,0092	0,0075	0,0065	0,0072	0,0069	0,0080
Ezüst	0,0133	0,0112	0,0091	0,0143	0,0108	0,0116	0,0117
Bitcoin	0,0989	0,0735	0,0448	0,0488	0,0696	0,0767	0,0687
Ethereum	0,0570	0,0994	0,0707	0,0729	0,0908	0,0570	0,0746
Litecoin	0,1604	0,1642	0,1006	0,1739	0,2907	0,1573	0,1745
EUR/USD	0,0035	0,0026	0,0025	0,0029	0,0096	0,0061	0,0045
GBP/USD	0,0059	0,0030	0,0028	0,0035	0,0078	0,0056	0,0048
AUD/USD	0,0044	0,0033	0,0029	0,0036	0,0035	0,0048	0,0038
Átlag	0,0338	0,0350	0,0234	0,0313	0,0448	0,0309	

Forrás: saját szerkesztés

A 13. táblázat (4. függelék) a 2020-as, azaz a Covid időszakra vonatkozó előrejelzések egyváltozós modelljeinek MAPE mutatóit tartalmazza. A legnagyobb becslési pontosságot az LSTM modell érte el az EUR/USD devizakeresznél 0,0049-es értékkel. A kapott eredmények alapján a leggyengébbnek pedig a legkevésbé komplex algoritmus az RNN tekinthető, amely a nyersolaj esetében csak 0,1770-es pontosságot volt képes elérni.

13. táblázat: A 2020. január 1. és 2020. június 30. közötti időszak egyváltozós módszerrel becsült MAPE mutatók

2020 Covid	Egyváltozós						
Termékek	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU	Átlag
S&P500	0,0190	0,0204	0,0194	0,0189	0,0203	0,0199	0,0197
DAX	0,0296	0,0279	0,0253	0,0300	0,0367	0,0335	0,0305
Nikkei225	0,0190	0,0174	0,0175	0,0219	0,0284	0,0179	0,0204
Nyersolaj	0,1770	0,1174	0,0845	0,1149	0,1080	0,0998	0,1169
Arany	0,0233	0,0145	0,0118	0,0151	0,0420	0,0147	0,0202
Ezüst	0,0203	0,0251	0,0203	0,0242	0,0254	0,0304	0,0243
Bitcoin	0,0411	0,0311	0,0301	0,0309	0,0404	0,0326	0,0344
Ethereum	0,0547	0,0364	0,0400	0,0402	0,0452	0,0477	0,0440
Litecoin	0,0482	0,0342	0,0533	0,0462	0,0451	0,0374	0,0441
EUR/USD	0,0064	0,0049	0,0053	0,0071	0,0075	0,0079	0,0065
GBP/USD	0,0081	0,0069	0,0062	0,0069	0,0087	0,0084	0,0075
AUD/USD	0,0125	0,0118	0,0098	0,0116	0,0107	0,0165	0,0122
Átlag	0,0383	0,0290	0,0270	0,0307	0,0349	0,0306	

Forrás: saját szerkesztés

A 14. táblázat a Covid időszak többváltozós módszerekkel történő becslési teljesítményeit hivatott bemutatni. A legpontosabb az LSTM modell lett 0,0025-ös értékkel, amelyet az EUR/USD devizapár esetében tapasztaltam. A koronavírus időszaka és a lezárások jelentősen hatással voltak a nyersolaj árfolyamára, ezáltal a volatilitására is, így nem meglepő, hogy ennek a terméknek az esetében volt a legnehezebb elkészíteni az előrejelzéseket. A leggyengébb eredményt az RNN-LSTM hibrid algoritmus produkálta 0,2935-tel. Megállapítható továbbá, hogy a többváltozós modellek alkalmazásával az LSTM teljesítménye tovább javult, azonban az olaj esetében az RNN-LSTM nem tudta kihasználni az ebből fakadó lehetőségeket.

14. táblázat: A 2020. január 1. és 2020. június 30. közötti időszak többváltozós módszerrel becsült MAPE mutatók

2020 Covid	Többváltozós						
Termékek	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU	Átlag
S&P500	0,0204	0,0209	0,0182	0,0186	0,0192	0,0192	0,0194
DAX	0,0396	0,0258	0,0224	0,0265	0,0386	0,0257	0,0298
Nikkei225	0,0257	0,0197	0,0177	0,0188	0,0221	0,0177	0,0203
Nyersolaj	0,2336	0,0921	0,0817	0,1058	0,2935	0,1095	0,1527
Arany	0,0204	0,0147	0,0115	0,0171	0,0485	0,0153	0,0213
Ezüst	0,0334	0,0245	0,0219	0,0233	0,0274	0,0277	0,0264
Bitcoin	0,0473	0,0279	0,0276	0,0338	0,0428	0,0418	0,0369
Ethereum	0,0496	0,0384	0,0431	0,0367	0,0431	0,0390	0,0417
Litecoin	0,0460	0,0377	0,0429	0,0336	0,0396	0,0835	0,0472
EUR/USD	0,0049	0,0025	0,0030	0,0043	0,0062	0,0046	0,0043
GBP/USD	0,0102	0,0034	0,0036	0,0034	0,0071	0,0056	0,0056
AUD/USD	0,0191	0,0092	0,0060	0,0076	0,0120	0,0082	0,0104
Átlag	0,0459	0,0264	0,0250	0,0275	0,0500	0,0332	

Forrás: saját szerkesztés

A 2022. februárjában kirobbant orosz-ukrán háború gazdasági hatásmechanizmusait és ezeknek az árfolyamelőrejelzésekre gyakorolt következményeit hivatott bemutatni a 15. és 16. táblázat. Az egyváltozós módszerek esetében a GRU bizonyult a leghatékonyabbnak, mégpedig a GBP/USD devizapárnál 0,0043-as MAPE mutatóval. A leggyengébb teljesítményt az RNN produkálta a Litecoin árfolyambecslése során (0,0644).

15. táblázat: A 2022. január 1. és 2022. június 30. közötti időszak egyváltozós módszerrel becsült MAPE mutatók

2022 háború	Egyváltozós						
Termékek	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU	Átlag
S&P500	0,0226	0,0145	0,0170	0,0169	0,0175	0,0144	0,0172
DAX	0,0173	0,0158	0,0155	0,0215	0,0207	0,0235	0,0191
Nikkei225	0,0139	0,0128	0,0205	0,0113	0,0123	0,0125	0,0139
Nyersolaj	0,0627	0,0437	0,0269	0,0501	0,0632	0,0339	0,0468
Arany	0,0089	0,0087	0,0131	0,0086	0,0096	0,0091	0,0097
Ezüst	0,0169	0,0145	0,0151	0,0151	0,0171	0,0172	0,0160
Bitcoin	0,0325	0,0435	0,0274	0,0509	0,0608	0,0345	0,0416
Ethereum	0,0446	0,0389	0,0357	0,0426	0,0614	0,0430	0,0444
Litecoin	0,0644	0,0367	0,0506	0,0513	0,0445	0,0642	0,0520
EUR/USD	0,0080	0,0057	0,0089	0,0109	0,0125	0,0102	0,0094
GBP/USD	0,0079	0,0049	0,0043	0,0045	0,0098	0,0065	0,0063
AUD/USD	0,0090	0,0059	0,0059	0,0061	0,0073	0,0062	0,0067
Átlag	0,0257	0,0205	0,0201	0,0242	0,0281	0,0229	

Forrás: saját szerkesztés

A többváltozós modellfuttatásoknál (16. táblázat) szintén a GRU lett a legjobb az EUR/USD vizsgálatánál nyújtott 0,0024-es értékkel. Míg a legkevésbé hatékony az RNN-LSTM volt a nyersolaj elemzésénél 0,0721-es MAPE eredménnyel.

16. táblázat: A 2022. január 1. és 2022. június 30. közötti időszak többváltozós módszerrel becsült MAPE mutatók

2022 háború	Többváltozós						
Termékek	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU	Átlag
S&P500	0,0161	0,0174	0,0144	0,0150	0,0153	0,0140	0,0154
DAX	0,0198	0,0238	0,0154	0,0162	0,0160	0,0326	0,0206
Nikkei225	0,0294	0,0125	0,0154	0,0111	0,0152	0,0126	0,0160
Nyersolaj	0,0343	0,0600	0,0269	0,0346	0,0721	0,0589	0,0478
Arany	0,0080	0,0077	0,0087	0,0111	0,0110	0,0088	0,0092
Ezüst	0,0195	0,0154	0,0145	0,0146	0,0244	0,0151	0,0173
Bitcoin	0,0367	0,0304	0,0319	0,0284	0,0441	0,0399	0,0352
Ethereum	0,0454	0,0433	0,0458	0,0438	0,0460	0,0468	0,0452
Litecoin	0,0478	0,0418	0,0653	0,0457	0,0590	0,0593	0,0532
EUR/USD	0,0058	0,0062	0,0024	0,0049	0,0091	0,0057	0,0057
GBP/USD	0,0089	0,0026	0,0027	0,0029	0,0031	0,0036	0,0040
AUD/USD	0,0047	0,0064	0,0039	0,0058	0,0058	0,0043	0,0052
Átlag	0,0230	0,0223	0,0206	0,0195	0,0268	0,0251	

Forrás: saját szerkesztés

5.5. Aktivációs függvény-optimalizálás

A szakirodalom hangsúlyozza (Singh et al., 2023; Apicella et al., 2021; Szandala, 2021; Dubey et al., 2022) az alkalmazott aktivációs függvények fontosságát a különféle előrejelző modelleknél. Ezért úgy gondoltam, hogy a tanulmányokban a regressziós modellek során legtöbbször használt lineáris ReLu függvényt két másik alternatívával is megpróbálom kiváltani és megvizsgálni, hogy okoz-e bármilyen változást a prediktív teljesítmény alakulásában. A további vizsgálatokat a három időszak legjobb és legrosszabb átlagos MAPE értékei alapján végeztem el az egy- és többváltozós becslési módszerekre egyaránt a tanh és a sigmoid függvények alkalmazásával. A legjobb algoritmusok esetében nem volt tapasztalható javulás a előrejelzési teljesítményben, azonban a legnehezebben becsülhető termékek esetében igen, így a Litecoin 2018-ra és 2022-re, valamint a nyersolaj 2020-ra vonatkozó modelloptimalizálás eredményeit az alábbiakban ismertetem.

A Litecoin 2018-as előrejelző modelleken eszközölt változtatások MAPE értékekre gyakorolt hatásait a 17. táblázat tartalmazza. Az egyváltozós LSTM és RNN-LSTM esetében egyik újonnan alkalmazott aktivációs függvénnyel sem sikerült javulást elérni, azonban az RNN (sigmoid) esetében 0,0819-re, a GRU-nál (sigmoid) 0,0755-re csökkentek a MAPE mutatókat. A legnagyobb előrelépés az LSTM-GRU és az RNN-GRU hibrid modelleknél történt. Mindegyik esetében a tanh függvény használata hozta meg a pozitív irányú változást. Előbbinél 0,1055-ös, míg utóbbinál 0,0861-es szintig sikerült optimalizálni a becslési pontosságot. A többváltozós modellezésnél az LSTM és a GRU teljesítményét nem sikerült tovább javítani. Az RNN-nél 0,0854-re csökkent a MAPE a sigmoid függvény használatának köszönhetően. A hibrid algoritmusok közül mindegyiknél előrelépés volt tapasztalható az új predikciók futtatása során. Az LSTM-GRU-nál 0,0829-es, az RNN-LSTM-nél 0,1809-es, míg az RNN-GRU-nál 0,1049-es eredmények generálódtak a tanh aktivációs függvény alkalmazása révén.

17. táblázat: A Litecoin egy- és többváltozós módszerrel becsült MAPE mutatói a különböző aktivációs függvények alkalmazása esetén a 2018. első féléves előrejelzésére vonatkozóan

Modell típusa	Aktivációs függvény	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU
Egyvált.	ReLu	0,1130	0,1912	0,1906	0,2490	0,1168	0,3389
	Tanh	Nem javult	Nem javult	0,1591	0,1055	Nem javult	0,0861
	Sigmoid	0,0819	Nem javult	0,0755	Nem javult	Nem javult	Nem javult
Többvált.	ReLu	0,1604	0,1642	0,1006	0,1739	0,2907	0,1573
	Tanh	0,1564	Nem javult	Nem javult	0,0829	0,1809	0,1049
	Sigmoid	0,0854	Nem javult	Nem javult	0,1277	0,2013	0,1352

Forrás: saját szerkesztés

A nyersolaj 2020-as további vizsgálata során (18. táblázat) azt a megfigyelést tettem, hogy az egyváltozós modelleknél optimálisabb hibaértékek a tanh függvény alkalmazásával csak az LSTM (0,1015) és az LSTM-GRU (0,1022) esetén generálódott. Jelentősebb javulás az RNN-nél következett be, ahol a sigmoid függvénnyel optimalizált algoritmus 0,1180-as értéket adott. Sokkal árnyaltabb a kép a többváltozós elemzéseknél, ugyanis ebben az esetben csak az LSTM-GRU modell volt képes nagyobb pontosságra. A GRU szerinti legjobb eredményt azonban egyik finomhangolt metódus sem tudta megközelíteni.

18. táblázat: A nyersolaj egy- és többváltozós módszerrel becsült MAPE mutatói a különböző aktivációs függvények alkalmazása esetén a 2020. első féléves előrejelzésére vonatkozóan

Modell típusa	Aktivációs függvény	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU
Egyvált.	ReLu	0,1770	0,1174	0,0845	0,1149	0,1080	0,0998
	Tanh	Nem javult	0,1015	Nem javult	0,1022	Nem javult	Nem javult
	Sigmoid	0,1180	Nem javult	Nem javult	Nem javult	Nem javult	Nem javult
Többvált.	ReLu	0,2336	0,0921	0,0817	0,1058	0,2935	0,1095
	Tanh	Nem javult	Nem javult	Nem javult	0,0943	Nem javult	Nem javult
	Sigmoid	Nem javult	Nem javult	Nem javult	Nem javult	Nem javult	Nem javult

Forrás: saját szerkesztés

A 2022-es időszakhoz kapcsolódó Litecoin árfolyamelőrejelzésekkel kapcsolatos módosított modellek MAPE értékeit a 19. táblázat tartalmazza. Nem sikerült további pontosságot elérni az egyváltozós RNN, LSTM, RNN-LSTM és az RNN-GRU futtatása során. A GRU (tanh) 0,0487-re, az LSTM-RNN (sigmoid) 0,0388-ra módosult. A többváltozós RNN, LSTM-GRU, RNN-LSTM sem hozott jobb értékeket. A tanh aktivációs függvény alkalmazásával azonban az LSTM (0,0387), a GRU (0,0389) és az RNN-GRU (0,0581) is javulni tudott.

19. táblázat: A Litecoin egy- és többváltozós módszerrel becsült MAPE mutatói a különböző aktivációs függvények alkalmazása esetén a 2022. első féléves előrejelzésére vonatkozóan

Modell típusa	Aktivációs függvény	RNN	LSTM	GRU	LSTM-GRU	RNN-LSTM	RNN-GRU
Egyvált.	ReLu	0,0644	0,0367	0,0506	0,0513	0,0445	0,0642
	Tanh	Nem javult	Nem javult	0,0487	0,0404	Nem javult	Nem javult
	Sigmoid	Nem javult	Nem javult	Nem javult	0,0388	Nem javult	Nem javult
Többvált.	ReLu	0,0478	0,0418	0,0653	0,0457	0,0590	0,0593
	Tanh	Nem javult	0,0387	0,0389	Nem javult	Nem javult	0,0581
	Sigmoid	Nem javult	Nem javult	Nem javult	Nem javult	Nem javult	Nem javult


Forrás: saját szerkesztés

5.6. Volatilitás vizsgálatának eredményei

A volatilitás és MAPE összefüggéseinek vizsgálatát az aktivációs függvényoptimalizálási folyamat után végeztem el. Az STL alapján számított relatív volatilitási mutatókat (CV_STL) és az átlagos MAPE értékeket a 7. függelék tartalmazza. A volatilitási értékek alapján egyértelműen kiemelkednek a kriptovaluták, különösen 2018-ban: az Ethereum (0,0475) és a Litecoin (0,0432) extrém magas értékeket mutatnak, szemben például a devizapárookra jellemző alacsony CV értékekkel (EURUSD: 0,0032). 2020-ban a nyersolaj mutat rendkívül magas volatilitást (0,1005), ami a Covid19 időszakához kapcsolható piaci sokkok következménye. A klasszikus részvényindexek, mint az S&P500 vagy a DAX, szintén magasabb volatilitással rendelkeztek 2020-ban, mint 2018-ban vagy 2022-ben, jelezve a piaci bizonytalanság fokozódását.

Az összevont és minden időszakra kiterjedő regressziós elemzés alapján (57. ábra) a relatív volatilitás (CV_STL) és az egyváltozós MAPE között szignifikáns, pozitív kapcsolat figyelhető meg. A regressziós koefficiens értéke 1,2937, ami azt jelenti, hogy a volatilitás egységnyi növekedése átlagosan 1,2937 egységgel növeli az előrejelzési hibát. Az együttható szignifikanciája ($p < 0,01$) megerősíti, hogy a kapcsolat statisztikailag is erős. A konstans értéke 0,0049, de nem szignifikáns, így a modellben a MAPE szintjét alapvetően a volatilitás szintje magyarázza. Az eredmény azt sugallja, hogy az egyváltozós modellek előrejelzési teljesítményét jelentősen befolyásolja a piac ingadozása. Az illeszkedés mértéke (R^2) 76,28%-os, amely meglehetősen magas magyarázóerőt feltételez. Az egyváltozós MAPE értékek tekintetében 2018-ban a legrosszabb predikciós teljesítmény a Litecoin esetében figyelhető meg (0,1095), amit a Bitcoin


követ (0,1011). Ugyanebben az évben a legalacsonyabb hibaértékek devizapárokhöz kötődnek, például a GBPUSD (0,0047) és az AUDUSD (0,0055) esetében. 2020-ban a nyersolaj a MAPE értékek (0,1023) tekintetében is kirívóan viselkedik megerősítve, hogy a piac hektikus mozgásai jelentősen rontják az előrejelzési teljesítményt.



57. ábra: A relatív volatilitás és az egyváltozós átlagos MAPE értékek kapcsolata időszakok szerinti megjelenítésben

Forrás: saját szerkesztés

A többváltozós modellben (58. ábra) a volatilitás hatása még erősebben jelentkezik: a CV_STL regressziós koefficiense 1,6224, amely szintén szignifikáns ($p < 0,01$). Ez arra utal, hogy a többváltozós előrejelzési rendszerek még érzékenyebbek a volatilitásra, vagyis a bemeneti komplexitás nem csökkenti, hanem esetenként növeli a hibaérzékenységet piaci ingadozás esetén. A konstans itt -0,0009, szintén nem szignifikáns, így a modell változékonyságának meghatározó tényezője továbbra is a relatív volatilitás. A magas koefficiens érték megerősíti, hogy még a fejlettebb, többváltozós modellek esetén is kulcsszerepet játszik a volatilitás a predikciós teljesítmény alakításában. Az illeszkedés mértéke (R^2) 90,58%-os, amely az egyváltozóséhoz képest még magasabb magyarázóerőt mutat. A MAPE értékek esetén a tendencia hasonló, de a hibák jellemzően alacsonyabbak vagy közel azonosak az egyváltozós modellekhez képest. Érdekesség, hogy 2018-ban a Litecoin többváltozós MAPE-je (0,1198) még magasabb is, mint az egyváltozós, ami prediktorválasztási problémákra utalhat. A legtöbb esetben azonban a többváltozós modellek kissé javítanak az előrejelzési pontosságon, például a Nikkei225 esetében 2020-ban (0,0203 vs. 0,0204), illetve a GBPUSD 2022-es értékeinél (0,0040 vs. 0,0063).



58. ábra: A relatív volatilitás és a többváltozós átlagos MAPE értékek kapcsolata időszakok szerinti megjelenítésben

Forrás: saját szerkesztés

A relatív volatilitás és a MAPE értékek kapcsolatát differenciált modellenkénti bontásban 2018-as, 2020-as és 2022-es időszakokra vonatkozóan a 19-21. táblázatok tartalmazzák, STL alapú megközelítésben. Ezeket a következőkben részletesen is bemutatom.

A 20. táblázat a relatív volatilitás (CV_STL) és az egy-, valamint többváltozós előrejelzési hibák (MAPE) közötti kapcsolatot mutatja be a 2018-as időszakra, hat-hat neurális hálózati modell esetében. Az eredmények alapján minden egyváltozós modell esetében szignifikáns, pozitív kapcsolat áll fenn a volatilitás és a MAPE között, vagyis minél magasabb az adott pénzügyi eszköz volatilitása, annál nagyobb a predikciós hiba. Az egyváltozós vizsgálatoknál a legnagyobb regressziós koefficiens az LSTM modell esetében figyelhető meg (2,920), míg a legalacsonyabb az GRU-nál (1,528), ami a különböző hálózati architektúrák eltérő érzékenységét jelzi a volatilitással szemben. Az R^2 értékek alapján szintén a GRU modell esetén figyelhető meg a legnagyobb magyarázóerő ($R^2 = 0,9713$), míg az RNN-nél a leggyengébb ($R^2 = 0,6134$). Az eredmények megerősítik, hogy a relatív volatilitás erős és stabil prediktora az egyváltozós predikciós teljesítménynek. A táblázat második része a relatív volatilitás és a többváltozós előrejelzési hibák (MAPE) közötti összefüggést mutatja be. Az eredmények azt jelzik, hogy minden modell esetében szignifikáns és pozitív kapcsolat áll fenn a volatilitás és az előrejelzési hiba között, ami arra utal, hogy a volatilisabb eszközöknél nagyobb hibával lehet előrejelezni az árfolyamokat több inputváltozó bevonása esetén is. A legmagasabb regressziós koefficiens a RNN-LSTM-nél figyelhető meg (2,856), míg a legalacsonyabb a LSTM-GRU-nál (1,662), ami azt

mutatja, hogy bizonyos architektúrák érzékenyebbek a volatilitás hatásaira. Az R^2 értékek alapján a LSTM-GRU esetén tapasztalható legjobb (0,9651), míg az RNN-LSTM-nél a alacsonyabb (0,7951) regressziós modellilleszkedés. Összességében elmondható, hogy az egy- és többváltozós modellek esetében is stabil, erős kapcsolat figyelhető meg a relatív volatilitás és a predikciós hiba között.

20. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és a MAPE értékeinek regressziós eredményei a nyugalmi időszakra vonatkozóan (2018)

	(1) Univ- RNN	(2) Univ- LSTM	(3) Univ- GRU	(4) Univ- LSTM- GRU	(5) Univ- RNN- LSTM	(6) Univ- RNN- GRU
CV_STL	2,422*** (0,608)	2,920*** (0,578)	1,528*** (0,083)	2,128*** (0,315)	2,304*** (0,168)	1,817*** (0,275)
Konstans	-0,002 (0,013)	-0,006 (0,013)	-0,000 (0,002)	-0,001 (0,007)	-0,003 (0,004)	0,002 (0,006)
Megfigyelések	12	12	12	12	12	12
R^2	0,6134	0,7185	0,9713	0,8207	0,9498	0,8132
	(7) Multi- RNN	(8) Multi- LSTM	(9) Multi- GRU	(10) Multi- LSTM- GRU	(11) Multi- RNN- LSTM	(12) Multi- RNN- GRU
CV_STL	1,830*** (0,264)	2,854*** (0,346)	1,810*** (0,188)	1,662*** (0,100)	2,856*** (0,458)	1,870*** (0,239)
Konstans	0,000 (0,006)	-0,008 (0,008)	-0,004 (0,004)	-0,001 (0,002)	-0,007 (0,010)	-0,001 (0,005)
Megfigyelések	12	12	12	12	12	12
R^2	0,8273	0,8720	0,9022	0,9651	0,7951	0,8595

Forrás: saját szerkesztés a STATA 17 eredmények alapján

Zárójelben a sztenderd hibák

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

A 21. táblázat a 2020-as időszakra vonatkozóan mutatja be a relatív volatilitás (CV_STL) és az egy-, valamint többváltozós előrejelzési hibák (MAPE) közötti kapcsolatot hat-hat neurális hálózati modell esetében. Az összes egyváltozós modell esetében a volatilitás regressziós együttthatója szignifikáns és pozitív, ami megerősíti, hogy a magasabb volatilitás a predikciós hiba növekedésével jár együtt ebben a válságokkal terhelt időszakban. A legalacsonyabb koefficiens a GRU modellnél (0,845), míg a legmagasabb az RNN modellnél (1,158) figyelhető meg, amely az architektúrák volatilitással szembeni eltérő érzékenységet tükrözi. Az R^2 értékek mindegyik modellnél rendkívül magasak (mindegyik meghaladja a 90%-ot), ami azt jelzi, hogy a regressziós elemzés magyarázóereje kiemelkedő a vizsgált időszakban. A táblázat második része a relatív

volatilitás (CV_STL) és a többváltozós előrejelzési hibák (MAPE) kapcsolatát hivatott bemutatni. Az eredmények ebben az esetben is minden modellnél statisztikailag szignifikáns és pozitív kapcsolatot jeleznek, vagyis a volatilitás növekedésével együtt nő a többváltozós predikciós hiba is. A legmagasabb regressziós együttható a RNN-LSTM modell esetén figyelhető meg (2,847), míg a legalacsonyabb érték a GRU-nál (0,828), ami a volatilitással szembeni nagyobb robusztusságra utalhat. A determinációs együtthatók (R^2) kiemelkedően magasak minden modellnél (86 és 98% közötti), különösen az LSTM esetében (0,9714), amely a legjobb magyarázóerővel bír. Ezek az eredmények megerősítik, hogy a 2020-as, pandémiával sújtott időszakban is fennállt az erős kapcsolat a piaci ingadozás mértéke és a modellek előrejelzési hibája között, még a fejlettebb, hibrid modellek esetében is.

21. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és a MAPE értékeinek regressziós eredményei a Covid19 időszakra vonatkozóan (2020)

	(1) Univ- RNN	(2) Univ- LSTM	(3) Univ- GRU	(4) Univ- LSTM- GRU	(5) Univ- RNN- LSTM	(6) Univ- RNN- GRU
CV_STL	1,158*** (0,067)	0,964*** (0,044)	0,845*** (0,077)	0,984*** (0,046)	0,984*** (0,100)	0,936*** (0,064)
Konstans	0,005* (0,002)	0,004** (0,002)	0,006** (0,003)	0,005*** (0,002)	0,011** (0,004)	0,007*** (0,002)
Megfigyelések	12	12	12	12	12	12
R^2	0,9676	0,9795	0,9228	0,9787	0,9067	0,9549
	(7) Multi- RNN	(8) Multi- LSTM	(9) Multi- GRU	(10) Multi- LSTM- GRU	(11) Multi- RNN- LSTM	(12) Multi- RNN- GRU
CV_STL	2,279*** (0,158)	0,896*** (0,049)	0,828*** (0,066)	0,911*** (0,050)	2,847*** (0,289)	1,150*** (0,146)
Konstans	-0,010* (0,006)	0,004** (0,002)	0,005* (0,002)	0,004** (0,002)	-0,020* (0,010)	0,005 (0,005)
Megfigyelések	12	12	12	12	12	12
R^2	0,9543	0,9714	0,9403	0,9706	0,9065	0,8616

Forrás: saját szerkesztés a STATA 17 eredmények alapján

Zárójelben a sztenderd hibák

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

A 22. táblázat a 2022-es időszakra vonatkozóan mutatja be a relatív volatilitás (CV_STL) és az egy-, valamint többváltozós előrejelzési hibák (MAPE) közötti. Minden egyváltozós modellnél pozitív és szignifikáns kapcsolat figyelhető meg, ami azt jelenti, hogy a volatilitás emelkedése továbbra is az előrejelzési hiba növekedésével jár együtt. A regressziós koefficiensek 1,149 (GRU)

és 1,969 (RNN-LSTM) között mozognak, ami viszonylag egységes, közepes érzékenységre utal a volatilitás hatására. A magyarázóerő (R^2) minden modell esetében magas, 85 és 92% közötti. A táblázat második része a relatív volatilitás (CV_STL) és a többváltozós előrejelzési hibák (MAPE) közötti kapcsolatot reprezentálja. Itt is minden modell esetében szignifikáns és pozitív regressziós együttható figyelhető meg. A koefficiensek viszonylag szűk sávban mozognak, a legalacsonyabb érték a GRU modell esetében (1,312), míg a legmagasabb az RNN-LSTM-nél jelentkezik (2,033), ami a különböző architektúrák eltérő volatilitás-érzékenységét mutatja. Az R^2 értékek magasak, 82 és 97% között alakulnak, kiemelkedő magyarázóerőt mutatva, különösen az LSTM-GRU esetében (97,48%). Az eredmények konzisztensen megerősítik a korábbi évek megfigyeléseit: a volatilitás strukturális jelenléte alapvetően befolyásolja a predikciós teljesítményt, még a komplexebb, többváltozós mélytanulási modellek esetében is.

22. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és a MAPE értékeinek regressziós eredményei az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

	(1) Univ- RNN	(2) Univ- LSTM	(3) Univ- GRU	(4) Univ- LSTM- GRU	(5) Univ- RNN- LSTM	(6) Univ- RNN- GRU
CV_STL	1,856*** (0,205)	1,403*** (0,132)	1,149*** (0,133)	1,539*** (0,192)	1,969*** (0,254)	1,598*** (0,165)
Konstans	-0,002 (0,004)	-0,000 (0,002)	0,003 (0,002)	0,000 (0,003)	-0,001 (0,005)	-0,001 (0,003)
Megfigyelések	12	12	12	12	12	12
R^2	0,8915	0,9192	0,8819	0,8656	0,8570	0,9032
	(7) Multi- RNN	(8) Multi- LSTM	(9) Multi- GRU	(10) Multi- LSTM- GRU	(11) Multi- RNN- LSTM	(12) Multi- RNN- GRU
CV_STL	1,370*** (0,153)	1,523*** (0,225)	1,312*** (0,115)	1,395*** (0,071)	2,033*** (0,225)	1,903*** (0,188)
Konstans	0,003 (0,003)	-0,000 (0,004)	-0,001 (0,002)	-0,001 (0,001)	-0,003 (0,004)	-0,003 (0,003)
Megfigyelések	12	12	12	12	12	12
R^2	0,8889	0,8206	0,9283	0,9748	0,8904	0,9112

Forrás: saját szerkesztés a STATA 17 eredmények alapján

Zárójelben a sztenderd hibák

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

A modellek összevont számszerűsíthető vizsgálatához és összehasonlításához készítettem egy panel regressziós elemzést is egy- és többváltozós megközelítésre vonatkozóan, az összes vizsgált időszakra, amelynek eredményeit a 23. táblázat tartalmazza. Az egyváltozós MAPE és a relatív volatilitás (CV_STL) kapcsolatának feltárása során arra a következtetésre jutottam, hogy az

együtthatók kivétel nélkül mind pozitívak és statisztikailag szignifikánsak ($p < 0.01$), ami arra utal, hogy a volatilitás emelkedése a panel regressziós modell esetén is szisztematikusan együtt jár a predikciós hibák növekedésével. A legnagyobb érzékenység az RNN-nél figyelhető meg (1,485), míg a legalacsonyabb a GRU esetében (0,923). Az R^2 értékek eltérő magyarázóerőt mutatnak: a legjobb értéket a GRU modell (0,8632) érte el, míg a legalacsonyabbat az LSTM (0,5259), ami jól tükrözi a modellek heterogén teljesítményét. A többváltozós neurális hálózati modellek esetében szintén mindenhol pozitív és szignifikáns kapcsolat figyelhető meg a relatív volatilitás és MAPE értékek között az összes időszakra aggregált panel regressziók alapján. A legmagasabb regressziós együttható az RNN-LSTM-nél látható (2,719), míg a legalacsonyabb a GRU-nál jelentkezik (1,035), ami ismételten a GRU modellek valamivel robusztusabb viselkedésére utal magasabb volatilitás mellett. Az R^2 értékek modellfüggően 60 és 90% között mozognak, tehát a magyarázóerő változó, de általában erős különösen a RNN modell esetében (90,72%), ami kiemelkedő illeszkedést jelez. Az eredmények alapján elmondható, hogy az egy- és többváltozós mélytanulási modellek esetében is fennáll a volatilitás előrejelzési hibára gyakorolt szisztematikus hatása, amely időszakokon átívelően is konzisztensek maradnak. Ez megerősíti a volatilitás kulcsszerepét a predikciós teljesítmény alakulásában még komplexebb modellstruktúrák mellett is.

23. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és a MAPE értékeinek panel regressziós eredményei az összes időszakra vonatkozóan

	(1) Univ- RNN	(2) Univ- LSTM	(3) Univ- GRU	(4) Univ- LSTM- GRU	(5) Univ- RNN- LSTM	(6) Univ- RNN- GRU
CV_STL	1,485*** (0,201)	1,418*** (0,231)	0,923*** (0,067)	1,274*** (0,135)	1,373*** (0,131)	1,185*** (0,114)
Konstans	0,004 (0,005)	0,003 (0,006)	0,006*** (0,002)	0,005 (0,004)	0,007* (0,003)	0,006** (0,003)
Megfigyelések	36	36	36	36	36	36
R ²	0,6157	0,5259	0,8632	0,7251	0,7645	0,7606
	(7) Multi- RNN	(8) Multi- LSTM	(9) Multi- GRU	(10) Multi- LSTM- GRU	(11) Multi- RNN- LSTM	(12) Multi- RNN- GRU
CV_STL	2,144*** (0,118)	1,369*** (0,192)	1,035*** (0,104)	1,117*** (0,073)	2,719*** (0,188)	1,198*** (0,112)
Konstans	-0,007** (0,003)	0,003 (0,005)	0,003 (0,003)	0,003 (0,002)	-0,012** (0,005)	0,006* (0,004)
Megfigyelések	36	36	36	36	36	36
R ²	0,9072	0,5982	0,7794	0,8734	0,8604	0,8102

Forrás: saját szerkesztés a STATA 17 eredmények alapján

Zárójelben a sztenderd hibák

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

A 23 táblázat összevont panel regressziós eredményei lehetőséget biztosítanak arra, hogy a modellek predikciós érzékenységet összehasonlítsuk a relatív volatilitás (CV_STL) függvényében. A regressziós koefficiensek pozitív értékei minden modell esetében megerősítik, hogy a volatilitás növekedése növeli az előrejelzési hibát (MAPE), ugyanakkor a koefficiensek nagysága alapján következtethetünk arra, mely modellek a legkevésbé érzékenyek a volatilitásra, azaz robusztusabbak. Ezek alapján először az egy- és többváltozós modellek összehasonlítás következik.

Az eredmények alapján világosan látszik, hogy a legtöbb modellpár esetében a többváltozós verzió érzékenyebben reagál a volatilitásra, mivel a CV_STL koefficiense nagyobb. Az RNN, a GRU, az RNN-LSTM, valamint az RNN-GRU esetében az egyváltozós modellek koefficiensei a kedvezőbbek. Az LSTM-nél és az LSTM-GRU-nál azonban pontosan az ellenkezője figyelhető meg. Összességében a legtöbb esetben a többváltozós modellek nagyobb érzékenységet mutatnak a volatilitással szemben, amit a magasabb regressziós koefficiensek jeleznek. Ez arra utal, hogy bár a többváltozós modellek jellemzően magasabb predikciós teljesítményt nyújtanak (magasabb R² értékek is ezt tükrözik, pl. Multi-RNN: 0,9072 szemben Univ-RNN: 0,6157), ugyanakkor

sérülékenyebbek lehetnek piaci turbulenciák esetén, azaz a predikciós hiba jobban függ a volatilitás szintjétől. Éppen ezért, alkalmazásuk során a volatilitásfüggőség explicit kezelése különösen indokolt lehet.

Az egyszerű és hibrid modellek összehasonlításával is fontos következtetésekre juthatunk. Az egyváltozós vizsgálatok esetén az RNN és az ebből képzett komplex módszerek eredményei alapján azt a megállapítást tehetjük az, hogy a hibridizált változatok kevésbé érzékenyen reagáltak a volatilitásra, mint az alapmodell. Ugyanez igaz az LSTM-re, valamint ennek hibrid változataira. A GRU-nál azonban pont az ellenkezője tapasztalható. Itt a hagyományos alaptípus kisebb volatilitás érzékenységet mutatott, mint a hibrid modellváltozatok. A többváltozós vizsgálatoknál a GRU alapmodell szintén jobban teljesített a hibridváltozatoknál. Az RNN, valamint az LSTM összehasonlításokat tekintve jóval vegyesebb a kép, mivel ezekben az esetekben előfordult, hogy a hibrid modell kisebb érzékenységet mutatott (RNN-GRU és LSTM-GRU) az alapváltozatnál.


A regressziós koefficiensek alapján megállapítható, hogy az egyváltozós modellek átlagosan kevésbé érzékenyek a volatilitásra, tehát robusztusabb teljesítményt mutatnak. Az egyszerű architektúrák (különösen GRU) alacsonyabb volatilitási érzékenységgel bírnak, mint a hibrid modellek. A hibrid modellek teljesítménye széles skálán mozog: míg egyesek (pl. RNN-LSTM) erősen érzékenyek a volatilitásra, mások (pl. RNN-GRU) meglepően stabilak. A modellválasztás tehát döntően befolyásolja, mennyire képes az adott architektúra ezt a hatást kezelni. Ez az összehasonlítás rámutat arra, hogy nemcsak a modellek típusát, hanem azok bemeneti struktúráját (egyváltozós vs. többváltozós) is gondosan mérlegelni kell predikciós rendszerek kialakításakor, különösen kimagasló volatilitású piaci környezetben.

5.7. Kereskedési stratégiák eredményeinek összehasonlítása

A kereskedési stratégiák alapját a legjobb előrejelző teljesítményt nyújtó modellek által generált prediktív értékek képezték minden időszak és termékkategória esetén. A továbbiakban a valós és becsült értékek visszatesztelésén alapuló módszerek hozam és kockázati mutatóinak összehasonlítása következik.

A 2018-as év adatai alapján (59. ábra és 7. függelék) világosan kirajzolódik, hogy a hagyományos buy-and-hold stratégia számos esetben alulmaradt a fejlettebb, gépi tanulásra épülő modellekkel szemben. Különösen érvényes ez a volatilis eszközosztályokra, például a kriptovalutákra és részben a nemesfémekre, de a részvény- és devizapiacokon is jól érzékelhető volt a prediktív modellek előnye. A részvénytőzsi indexeknél (S&P500, DAX) is egyértelműen kirajzolódott a MAPE-modellek fölénye. Az S&P500 esetében például a buy-and-hold csupán 0,83%-os kumulált hozamot ért el, míg a MAPE-alapú stratégiák 12-14% közötti eredményt produkáltak kiemelkedő, 2,65 körüli Sharpe-mutató mellett. A DAX esetében a buy-and-hold negatív hozama (-17,12%) kontrasztban állt a MAPE-modellek pozitív teljesítményével, amelyek nemcsak javuló hozamot, hanem jelentősen kedvezőbb kockázati profilt is mutattak. A Nikkei225 indexnél azonban minden stratégia negatív hozamot generált. Az arany és az ezüst esetében is egyértelmű hozamnövekedés volt tapasztalható. A MAPE-pozíció stratégia például az arany esetében 7,02%-os hozamot és 3,1859-es Sharpe-mutatót produkált, miközben a buy-and-hold alig mutatott pozitív teljesítményt. Egyedüli kivételt a nyersolaj jelentett: míg a buy-and-hold stratégia 20,56%-os pozitív hozamot ért el, addig az aktív stratégiák nem tudtak érdemben javítani ezen. A prediktív modellek Sharpe-mutatói negatívak voltak, a maximális visszaesések pedig jóval magasabb szintet értek el (pl. MAPE-szűrő: 0,5712), ami arra utal, hogy a modell nem tudta megfelelően lekövetni az olajpiac nemlineáris és turbulens mozgásait. A legmarkánsabb különbségek a kriptovaluták esetében jelentkeztek. A Bitcoin buy-and-hold hozama erősen negatív volt (-73,38%), míg az Alapstratégia több mint 86%-os kumulált hozamot ért el. Hasonlóan jelentős volt a javulás az Ethereum és a Litecoin esetében, ahol a gépi tanulási alapú stratégiák jelentős hozamelőnyt biztosítottak, a Sharpe-mutatók pedig rendre meghaladták a 2-t. A devizapároknál (EURUSD, GBPUSD, AUDUSD) a gépi tanulási modellek Sharpe-mutatói jellemzően pozitívak és magasabbak voltak, mint a buy-and-hold stratégiáé, még akkor is, ha az abszolút hozamszintek mérsékeltek maradtak. Emellett szinte minden esetben alacsonyabb maximális visszaesést (drawdown) eredményeztek. Általánosságban elmondható, hogy az Alap-, MAPE-szűrő és MAPE-pozíció stratégiák 2018-ban szinte minden eszközosztályban felülmúlták a buy-and-hold megközelítést, különösen hozam és kockázat-hozam arány (Sharpe-mutató) tekintetében. A maximális visszaesés szintén alacsonyabb maradt a prediktív modellek esetében, ami a hatékonyabb kockázatkezelésre utal. A kivételt jelentő

olajpiac kiemeli, hogy bár a gépi tanulás ígéretes eszköz a pénzügyi előrejelzésekben, vannak olyan piaci környezetek, ahol a prediktív teljesítmény nem garantált.




59. ábra: A 4 kereskedési stratégia összehasonlítása a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A Covid19 által fémjelzett 2020-as év (60. ábra és 8. függelék) extrém piaci környezete élesen megvilágította a különböző befektetési stratégiák közötti teljesítménykülönbségeket. A hagyományos buy-and-hold megközelítés számos eszközosztályban alulmaradt a gépi tanulásra épülő, adaptív stratégiákkal szemben, amelyek nemcsak magasabb hozamot, hanem jobb kockázat/hozam arányt és kisebb maximális visszaesést is biztosítottak. Az S&P500 példája különösen jól szemlélteti a prediktív stratégiák előnyeit. Míg a buy-and-hold hozama enyhén negatív volt (-5,65), az Alapstratégia 74,26%-os kumulált hozamot produkált. A Sharpe-mutató a prediktív modelleknél extrém magas értéket (4,7) vett fel, szemben a buy-and-hold negatív arányával (-0,2465). A DAX és a Nikkei225 esetében is hasonló eredmények születtek: a hagyományos stratégia veszteségei mellett a MAPE-alapú modellek pozitív hozamot és jóval kedvezőbb kockázati mutatókat biztosítottak. A nemesfémek esetében szintén jól teljesítettek az aktív stratégiák. Az aranynál a MAPE-pozíció stratégia 23%-os hozamot és 2,48-as Sharpe-mutatót ért el, egyértelműen felülteljesítve a buy-and-hold-ot. A maximális visszaesések is mérsékeltebbek voltak az aktív modellek esetében, ami a jobb kockázatkezelést tükrözi. A nyersolajpiac 2020-ban is kivételként viselkedett. Míg a buy-and-hold stratégia 17,12%-os hozamot mutatott, az aktív stratégiák jelentős veszteségeket szenvedtek el (-45,52%) és negatív tartományba eső Sharpe-mutatókat produkáltak. Ez valószínűleg annak tudható be, hogy a piaci

extrémítások (negatív határidős árfolyam) olyan strukturális változásokat jelentettek, amelyekre a prediktív algoritmusok nem voltak felkészítve. A modellek a szokványos volatilitási mintázatokat követve téves irányokat preferáltak, ez pedig látványosan rontotta az eredményeket. A kriptovaluták piacain az aktív megközelítések szinte minden esetben jelentős felülteljesítést eredményeztek. A Litecoin buy-and-hold hozama 1,23%, míg a prediktív stratégia 127,96%-os kumulált hozamot és 2,75 fölötti Sharpe-mutatót hozott. A Bitcoin és Ethereum esetében is hasonló volt a tendencia. A gépi tanulási modellekre alapozott stratégiák (Alapstratégia és MAPE-pozíció) hozama meghaladta a 100%-ot és stabilan 2-3 közötti Sharpe-értéket mutattak. A devizapiacokon azonban a prediktív stratégiák előnye, már kisebb mértékben volt érzékelhető. Bár az abszolút hozamkülönbségek nem voltak drámaiak, a gépi tanulási modellek a legtöbb esetben javították a kockázat/hozam arányt és csökkentették a visszaesést. A 2020-as évben, a rendkívüli piaci volatilitás közepette, a gépi tanulási stratégiák nem csupán alternatívát, hanem számos esetben hatékonyabb és stabilabb megoldást nyújtottak a portfóliókezelés során. Az aktív stratégiák kiemelkedő eredményeket értek el a részvényt piacokon, a kriptoeszközök piacán és a nemesfémek területén. A devizapiacokon mérsékeltebb, de stabil javulást hoztak. Ugyanakkor az olajpiac ismételten kihívás elé állította a prediktív rendszereket.




60. ábra: A 4 kereskedési stratégia összehasonlítása a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés

A 2022-es év piaci környezete (61. ábra és 9. függelék) jelentős kihívások elé állította a befektetőket. A geopolitikai feszültségek, az inflációs nyomás és a monetáris szigorítások komoly volatilitást eredményeztek a hagyományos eszközosztályokban. Ebben a bizonytalan

környezetben a prediktív, gépi tanulási modellekre épülő stratégiák több esetben is hatékony védelmet nyújtottak a veszteségekkel szemben, sőt, sokszor pozitív hozamot biztosítottak ott, ahol a buy-and-hold jelentős visszaesést szenvedett el. A részvényt piacokon a buy-and-hold megközelítés nem tekinthető hatékonynak ugyanis az S&P500 index -22,42%-os hozamot produkált -1,81-es Sharpe-mutató mellett, míg az Alapstratégia 13,49%-os pozitív eredményt és 1,46-os Sharpe-mutatót ért el. A DAX esetében még erőteljesebb volt a kontraszt. A buy-and-hold -31,16-os hozammal és -2,06-os Sharpe-mutatóval zárt, míg a prediktív stratégiák pozitív teljesítményt mutattak, bár szerényebb mértékben. A Nikkei225 esetében is egyértelmű az aktív stratégiák fölénye. A buy-and-hold -7,55%-os, míg az Alapstratégia 18,55%-ra hozamszinteket produkált, rendkívül magas (2,16) Sharpe-mutató mellett. Az arany és az ezüst esetében a prediktív stratégiák a hozamot növelték és jobb Sharpe-mutatót értek el, mint a passzív megközelítés. A nyersolaj ismételten kivételként viselkedett. A buy-and-hold stratégia kimagasló, 35,48%-os hozamot realizált, szemben a versenytárs módszerekkel, amelyek közül csak a MAPE-szűrő volt képes pozitív eredményre (10,89%). Ez az eltérés azt jelezheti, hogy a nyersolaj ármozgását olyan nemlineáris, szokatlan dinamikák mozgatták (geopolitikai sokkok, ellátási lánc anomáliák), amelyekre a gépi tanulási algoritmusok nem tudtak megfelelően reagálni. A kriptopiacokat 2022-ben brutális korrekció jellemezte. A Bitcoin (-85,01%), Ethereum (-120,93%) és Litecoin (-101,92) buy-and-hold hozamai súlyos veszteségeket mutattak. Ugyanakkor a prediktív stratégiák jelentős veszteségcsökkentést értek el, amely különösen a Litecoin esetében látványos, mivel az Alapstratégiával 49,07%-os hozamot sikerült realizálni, 2,17-es Sharpe-mutató mellett. A Bitcoin esetében is nyereséget mutatott az aktív stratégiaépítés, azonban az Ethereumnál nem sikerült kompenzálni a negatív trendet. A devizapiacokon is kedvezőbb eredményeket hoztak a prediktív stratégiák. Az EURUSD buy-and-hold -7,65%-os hozammal zárt, míg az Alapstratégia MAPE-alapú stratégia 7,91%-ot produkált 2,57-es Sharpe-mutatóval. A GBPUSD és AUDUSD esetében a kép vegyesebb, de a passzív megközelítés ott is gyengébben teljesített. A 2022-es év során a gépi tanulásra épülő prediktív stratégiák megerősítették létjogosultságukat, különösen a válságjellegű, szélsőséges piaci helyzetek kezelésében. A részvényt piacokon, kriptovalutáknál, nemesfémeknél és több devizapáron is képesek voltak a veszteségeket csökkenteni, sőt sok esetben pozitív hozamot biztosítani. A Sharpe-mutatók javulása egyértelműen mutatja, hogy ezek a modellek hatékonyabban kezelik a kockázatot. Az olajpiac azonban továbbra is kritikus pontnak tekinthető, mivel a prediktív modellekre épülő befektetési módszertanok rendre alulteljesítettek ezen az eszközosztályon.




61. ábra: A 4 kereskedési stratégia összehasonlítása az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

A három vizsgált év során általánosan megfigyelhető, hogy a gépi tanuláson alapuló aktív stratégiák szisztematikusan túlteljesítették a buy-and-hold megközelítést, mind hozam, mind kockázat/hozam arány szempontjából. Ez a tendencia különösen a részvénypiacokon és a kriptovaluták piacán volt jellemző. A legnagyobb különbségek azokban az években jelentkeztek, amikor a piac volatilis volt (pl. 2020, 2022), ami alátámasztja, hogy a gépi tanulási stratégiák hatékonyabban tudják kezelni a turbulens környezetet. Kiemelkedően fontos kivétel azonban a nyersolaj, amely minden évben gyenge eredményeket hozott az aktív stratégiáknál. Ennek oka lehet az árupiaci sajátosságokban, a fundamentális események (geopolitika, OPEC-döntések) nehezen előrejelezhető hatásaiban, valamint abban, hogy az olaj ármozgása gyakran hirtelen, szűk időablakokban történik meg. Összességében tehát a gépi tanulási stratégiák széles körű alkalmazása sikeresnek mondható, de bizonyos eszközosztályok (olaj) esetén szükség lehet a modellek továbbfejlesztésére vagy kombinálására más prediktív eszközökkel. Mindezek alapján a prediktív modellek alkalmazása értékes kiegészítője lehet a befektetési döntéseknek, de nem helyettesítik a körültekintő piaci értelmezést. Ez rámutat arra, hogy bár a mesterséges intelligencia nagy potenciált rejt magában, egyik modell sem univerzális megoldás minden piaci szituációra.

Az egyedi eszközök teljesítményértékelésén túlmenően különböző súlyozású portfóliókkal is kísérleteztem, melynek a bemutatását az alábbiakban részletezem.

A 62. ábra (11. függelék) a 2018-as évre mutatja a négy különböző eszközosztályra épülő, azonos eszközszúlyozású portfóliók (1/3-os súllyal szerepel minden eszköz) kumulált hozamát stratégiák szerinti bontásban. A buy-and-hold megközelítés minden portfólió esetén alulteljesít, különösen a kriptovaluták esetében, ahol drasztikus, -75,13%-os veszteség figyelhető meg. Ezzel szemben az Alapstratégia jelentősen javítja a teljesítményt, különösen a kriptovaluta-portfóliónál, ahol 100,54%-os kumulált hozamot ér el, vagyis teljes mértékben felülmúlja a passzív befektetési megközelítést. A MAPE-szűrőre és MAPE-pozícióra épített modellek stabilabb, konzervatívabb eredményeket mutatnak: az árupiaci portfóliónál például mindkettő 12% körüli hozamot produkál, felülmúlva a buy-and-hold-ot. A részvényt piac és a devizapiac esetén is érzékelhető javulás tapasztalható az aktív stratégiákkal, különösen a MAPE-alapú megközelítések révén. A kriptovaluta-portfólió esetében a MAPE-szűrő visszafogottabb, de még így is pozitív teljesítményt nyújt (15,21%), míg a MAPE-pozíciós stratégia 89,91%-ot ér el, ami kiemelkedő eredmény egy ilyen extrém volatilitású környezetben. Összességében az aktív, predikció alapú hatékonyan képesek kezelni a magas kockázatú piaci körülményeket (kriptovaluták), míg a konzervatívabb eszközosztályoknál is mérsékelt hozamjavulás érhető el.




62. ábra: Azonos súlyozású termékcsoportonkénti portfóliók kumulált féléves hozam a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A 63. ábra a 2020-as év különféle portfóliókra vonatkozó kumulált hozamait tartalmazza (11. függelék). Megfigyelhető, hogy jelentős eltéréseket mutatkoznak a különböző eszközosztályok és stratégiák mentén. A részvényt piaci portfólió esetében a buy-and-hold stratégia negatív eredményt hozott (-7,51%), míg az Alapstratégia és a MAPE-pozíció jelentős pozitív teljesítményt mutatott

(37,74% és 36,90%), jelezve, hogy az aktív, predikcióalapú megközelítések válságos környezetben is képesek felülteljesíteni. Az árupiaci portfóliónál ugyan a buy-and-hold stratégia hozama pozitív volt (11,17%), az Alap- és MAPE-pozíció stratégiák eredményei negatívak lettek (-2,11% és -1,92%), ami arra utalhat, hogy ezek az aktív modellek nem tudtak jól alkalmazkodni a piaci dinamikákhoz ebben a szegmensben. A kriptovaluta-portfólió minden stratégia szerint kiemelkedő hozamot produkált különösen az Alapstratégia (120,96%) és a MAPE-pozíció (107,37%) ért el rendkívüli teljesítményt, felülmúlva a buy-and-hold-ot is (27,43%). A devizapiacra a hozamok alacsonyok maradtak minden megközelítés esetében, de a predikciós alapú stratégiák itt is jobb eredményt értek el, mint a passzív buy-and-hold. Összességében a gépi tanuláson alapuló stratégiák különösen a magas volatilitású piacokon (kriptovaluták, részvények) tudtak kiemelkedő teljesítményt nyújtani, míg a stabilabb vagy kiszámíthatatlanabb piacokon (árupiac, deviza) a teljesítményük mérsékeltebb vagy esetenként alulteljesítő volt.




63. ábra: Azonos súlyozású termékcsoportonkénti portfóliók kumulált féléves hozam a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés

A 2022-es év adatai alapján (64. ábra, 11. függelék) a buy-and-hold stratégia minden portfólió esetében gyenge teljesítményt mutatott, különösen a kriptovaluta portfóliónál, ahol extrém mértékű, -103,05%-os kumulált veszteség jelentkezett. Ezzel szemben az Alapstratégia minden esetben felülteljesítette a passzív megközelítést, különösen a részvényt piacon (13,05%) és a kriptopiacacon (24,23%), ahol a volatilitás ellenére is sikerült pozitív hozamot elérni. A MAPE-szűrő stratégia stabilabb, mérsékeltebb eredményeket mutat ugyanis a részvények és az árupiaci eszközök esetében is 10% feletti hozamot biztosított, míg a kriptovalutáknál kismértékű negatív

hozammal zárt (-1,67%). A MAPE-pozíció stratégia szintén kiemelkedő volt a részvény- (12,29%) és kriptovaluta-portfólióban (21,99%) megerősítve, hogy az előrejelzési hibákra alapozott pozíciókezelés hatékonyan képes csökkenteni a kockázatot turbulens piaci környezetben. Az árupiaci portfólió esetében ugyanakkor mind az Alap-, mind a MAPE-pozíciós stratégia enyhe veszteséget mutatott, ami azt jelezheti, hogy az adott piaci mozgásokat ezek a modellek kevésbé tudták jól követni. A devizapiac esetében minden megközelítés közel azonos és szerény pozitív hozamot eredményezett (kb. 1,4-2,1%), ami az alacsony volatilitásra és kisebb előrejelezhetőségi potenciálra utalhat. Összességében az aktív, predikciós alapú stratégiák 2022-ben is felülteljesítették a buy-and-hold megközelítést, különösen a részvény- és kriptopiacon, még extrém piaci stresszhelyzetek közepette is.




64. ábra: Azonos súlyozású termékcsopontonkénti portfóliók kumulált féléves hozam az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

A 65. ábra azonos súlyozású portfóliók (minden termék 1/12-es súllyal szerepel) kumulált hozamát mutatja három különböző évben, négyféle stratégiai megközelítés szerint. A buy-and-hold stratégia, 2018-ban és 2022-ben jelentős veszteséget mutatott (-19,86%, illetve -30,70%), míg 2020-ban mérsékelt 7,12%-os hozamot ért el. Ezzel szemben az Alapstratégia minden vizsgált évben pozitív kumulált hozamot generált, kiemelkedően 2020-ban (39,75%) és 2018-ban is erőteljesen felülteljesítve a buy-and-hold-ot (29,52%). A MAPE-szűrőre épülő stratégiától visszafogottabb, de jellemzően stabilabb eredményeket láthatunk. 2018-ban 8,98%, 2020-ban 20,52%, míg 2022-ben 5,26%-os pozitív hozammal zárt. A MAPE-pozíció megközelítés teljesítménye szintén szignifikánsan jobb, mint a passzív stratégia, különösen 2020-ban és 2018-

ban, amikor +36,17%, illetve +27,60%-os kumulált hozamot ért el. Mindez arra utal, hogy az előrejelzési hibákra (MAPE) épített szűrés és pozíciókezelés segíthet csökkenteni a negatív piaci hatásokat, illetve növeli a teljesítmény stabilitását a változó környezeti feltételek mellett.



65. ábra: A 12 termékből kialakított azonos súlyozású portfóliók fél éves kumulált hozama a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018, 2020 és 2022)

Forrás: saját szerkesztés

6. KÖVETKEZTETÉSEK ÉS JAVASLATOK

A kutatás célja az volt, hogy feltárja a gépi tanulási algoritmusok, különösen a mély neurális hálózatok alkalmazhatóságát pénzügyi eszközök árfolyamainak előrejelzésére, különböző piaci környezetekben és terméktípusokon. A vizsgálat a predikciós modellek volatilitásérzékenységére, az előrejelzések megbízhatóságára és azok gyakorlati felhasználhatóságára fókuszált. A dolgozat alapvetően két fő célkitűzés alapján vizsgálta a témakört. Az első az előrejelző modellek teljesítménye és a piaci volatilitása közötti összefüggéseire, valamint az egyes modellek különböző gazdasági ciklusokban való alkalmazhatóságára fókuszál. A második célkitűzés pedig a gépi tanulási modellek által támogatott kereskedési stratégiák gyakorlati teljesítményére helyezi a hangsúlyt. Az elemzés során külön figyelmet kapott a részvényindexek, árupiaci termékek, kriptovaluták és devizapárok modellezése, mivel ezek volatilitása, likviditása és szabályozottsága nagymértékben eltér. A kutatás során végzett empirikus elemzések alapján több szempontból is megalapozott következtetések vonhatók le, melyet az alábbiakban részletezek.

C1: A kutatásom első célkitűzése annak meghatározása, hogy a különböző neurális mély tanulási modellek milyen mértékben általánosíthatóak, azaz képesek-e különböző válsághelyzetekben is kimagasló prediktív teljesítmény elérésére.

K1: Milyen kapcsolat mutatható ki a pénzügyi eszközök volatilitása és az árfolyamelőrejelzési modellek prediktív teljesítménye között?

A regressziós modellek alapján egyértelműen kimutatható, hogy a volatilitás, jelen esetben a trend és szezonálismentes (CV_STL) relatív szórás szignifikáns, pozitív kapcsolatban áll az előrejelzési hibával (MAPE). Eredményeim szerint minden vizsgált modellkategória esetén romlik az előrejelzési pontosság, ahogy nő a piaci volatilitás, amely különösen szembetűnő a kriptovaluták esetén, de megfigyelhető az árupiaci termékeknél is. Ezzel összhangban áll több tanulmány megállapítása is, amelyek hangsúlyozzák a nemlineáris és nem stacionárius adatok előrejelzésének nehézségeit (Ouyang et al., 2021; Zhang et al., 2023; Avinash et al., 2024). A mélytanulás e kihívásokat részben képes kezelni, de a turbulens piacokon tapasztalható hirtelen elmozdulások továbbra is problémát jelentenek a predikciós megbízhatóság szempontjából.

K2: Milyen előrejelzési torzulásokat okoznak a válságidőszakokban megfigyelhető szélsőséges árfolyammozgások és hogyan reagálnak erre különböző típusú algoritmusok?

A 2020-as és 2022-es válságidőszakok jól demonstrálták, hogy a modellek teljesítménye eltérően reagál az extrém árfolyammozgásokra. A GRU modellek például meglepően stabilnak bizonyultak, míg az RNN-t tartalmazó hibrid architektúrák (pl. RNN-LSTM) teljesítménye érdemben romlott, tehát a válságidőszakok nemcsak a predikciós hiba növekedését, hanem a

modellek közötti teljesítménykülönbségek erősödését is okozták. Ez megerősíti a szakirodalomból ismert megállapításokat, miszerint a túl komplex modellek nagyobb mértékben ki vannak téve az instabilitásnak (Livieris et al., 2020), illetve arra is rávilágít, hogy az előrejelző algoritmusok a fejlettségi szinttől függetlenül is érzékenyek a piaci sokkok okozta szélsőséges árfolyammozgásokra, ezért kiemelt fontossággal bír ezen tényezők figyelembevétele az előrejelző módszerek fejlesztése során (Mari és Mari, 2023 és 2025; Sivakumar, 2025).

K3: Milyen szerepet játszik a hibrid modellek architektúrája a prediktív teljesítmény változásában volatilis piaci környezetben?

A dolgozat eredményei alapján megállapítható, hogy a prediktív modellek architektúrája, különösen a hibrid mélytanulási struktúrák, jelentős szerepet játszik az előrejelzési teljesítmény alakulásában, különösen volatilis piaci környezetben. Az empirikus vizsgálatok azt mutatták, hogy az olyan modellek, amelyek első réteggként RNN-komponenst használnak, gyakran gyengébben teljesítettek a többi architektúrához képest különösen a kriptovaluták esetében. Ez az eredmény részben összhangban van Liang et al. (2022) és Ouyang et al. (2021) megállapításaival, akik arra hívták fel a figyelmet, hogy a bonyolultabb, Attention-alapú vagy Transformer-típusú architektúrák robusztusabb teljesítményt nyújthatnak extrém piaci környezetekben. Ugyanakkor a disszertációban vizsgált egyszerűbb LSTM- vagy GRU-alapú modellek több esetben is stabilabbnak bizonyultak az RNN-modulokkal szemben, különösen hibrid felépítés esetén, ami alátámasztja a hibrid architektúrák finomhangolásának fontosságát. A modellek belső szerkezete tehát nem csupán technikai preferencia kérdése, hanem a volatilitás kezelésének kulcsfontosságú eleme.

C2: A dolgozatom második célkitűzése annak a vizsgálata, hogy a gépi tanulási modellek milyen mértékben képesek javítani a pénzügyi eszközök kereskedési teljesítményét a hagyományos buy-and-hold stratégiához képest.

K4: Mennyiben képesek a gépi tanulási előrejelzéseken alapuló kereskedési stratégiák kihasználni a piaci anomáliákat, a hatékony piacok elméletével szemben?

A szabályalapú, predikcióvezérelt kereskedési stratégiák visszatesztelése igazolta, hogy több időszakban és terméktípus esetén is meghaladták a buy-and-hold referenciahozamot. A MAPE-szűrővel ellátott változatok további kockázatkezelést tettek lehetővé, mivel képesek voltak kiszűrni az alacsony predikciós biztonságu pozíciókat. Eredményeim megerősítik Viéitez et al. (2024) és Ju et al. (2024) megállapításait, akik szerint a modellek predikciós képességein túl azok adaptív használata, például pozíciószűrés formájában, nagymértékben javítja a gyakorlati teljesítményt. A Sharpe-mutató esetében megfigyelhető volt, hogy a prediktív stratégia általában magasabb értéket mutatott, ami a hozam volatilitására vetített jobb kockázat-hozam arányt jelez.

Ez a megállapítás szembe megy a hatékony piacok elméletének (EMH) azon tételével, miszerint hosszú távon nem lehet szisztematikusan meghaladni a piacot minden elérhető információ figyelembevételével (Fama, 1970).

K5: Milyen hatása van a különböző termékosztályok (pl. részvények, kriptovaluták, árupiac, devizapárok) volatilitásának a gépi tanulás által támogatott kereskedési stratégiák teljesítményére?

Eredmények szerint a kriptovaluták kiszámíthatatlansága és a devizapárok stabilitása markánsan eltér, ami közvetlen hatással van a kereskedési eredményekre. A termékspecifikus elemzések tehát rávilágítottak arra, hogy a volatilitás különböző módon hat a stratégiák teljesítményére. A kriptovaluták esetében a MAPE-szűrő különösen hatékony volt a veszteségek csökkentésében, míg a devizapiacokon az Alapstratégia stabilitása volt kiemelkedő. A részvénypiacokon a stratégiák egymáshoz viszonyított teljesítménye inkább időszakfüggőnek bizonyult, amely összhangban van a szakirodalom megállapításaival, miszerint az eszközszer specifikus volatilitás eltérő modellezési megközelítést kíván (Yu et al., 2023; Aydogan-Kilic és Selcuk-Kestel, 2023). Az eredmények alátámasztják, hogy termékspecifikus paraméterezés szükséges a maximális hatékonyság eléréséhez. Egy további fontos következtetés, hogy az azonos súlyozású portfóliók esetében a predikcióvezérelt stratégiák teljesítménye nem minden piaci szegmensben volt egységes. Az árupiaci és devizapiaci eszközök esetében kisebb volt az eltérés a stratégiai variánsok között, míg a kriptovalutákban drasztikus különbségek mutatkoztak. Ez ismételten megerősíti, hogy a stratégia és modell hatékonysága csak adott terméktípus és időszak viszonylatában értelmezhető, így a modellválasztásnak és a paraméterhangolásnak döntő szerepe van a gyakorlati eredményességben.

K6: Milyen eltérések tapasztalhatók a gépi tanuláson alapuló stratégiák teljesítményében különböző gazdasági ciklusok alatt?

A kereskedési stratégiák teljesítménye jelentős eltérések mutatkoztak különböző piaci környezetekben. A 2018-as nyugodt piaci környezetben szinte minden modell alapú stratégia stabil nyereséget hozott. Ezzel szemben 2020-ban és 2022-ben a predikciós teljesítmény visszaesett a volatilitás erősödése miatt. Azonban MAPE-szűrős rendszerek csökkentették a veszteségek kockázatát, ami megerősíti Ouyang et al. (2021) figyelemalapú volatilitáskezelési stratégiáinak gyakorlati relevanciáját és kiemeli az adaptív döntési mechanizmusok fontosságát. Ezek a megállapítások megerősítik azt a szakirodalmi álláspontot (Kang et al., 2025), miszerint a predikciós rendszereknek alkalmazkodniuk kell a gazdasági rezsimek változásaihoz. A stratégiák teljesítménye így nemcsak a modell pontosságától, hanem annak volatilitásérzékeny alkalmazásától is függ. A kutatás egyik legfontosabb következtetése tehát az, hogy a gépi tanulási

alapú kereskedési rendszerek csak akkor tudnak stabil teljesítményt nyújtani válsághelyzetekben, ha beépített predikciós validációs mechanizmusokkal és adaptív szűréssel is rendelkeznek.

A disszertáció empirikus eredményei alátámasztják, hogy a gépi tanulási modellek hatékony predikciós eszközt jelentenek, de teljesítményük szignifikánsan függ a volatilitástól, a piaci rezsimtől és az eszköz típusától. A predikciókra épülő stratégiák alkalmazása során elért többlet hozam és kockázatsökkentés bizonyítja, hogy az ilyen rendszerek értékes kiegészítői lehetnek a befektetési döntéstámogatásnak, mivel nemcsak elméleti, hanem gyakorlati előnnyel is bírnak, feltéve, hogy megfelelően integrálják az előrejelzési bizonytalanság mérését és a piac volatilitásához való alkalmazkodást.

Limitációk

A disszertáció számos új eredményt mutatott be a gépi tanulási modellek predikciós teljesítményéről és volatilitásérzékenységéről, valamint azok kereskedési stratégiákba történő integrációjáról. Ugyanakkor fontos megemlíteni azokat a korlátokat, amelyek befolyásolhatják az eredmények általánosíthatóságát vagy további kutatásokra adhatnak ösztönzést. A vizsgálat három kiemelt év (2018, 2020, 2022) adataira épült, amelyek ugyan lefedik a nyugalmi és válságperiódusokat, de nem biztosítanak teljes reprezentációt a hosszú távú gazdasági ciklusok változatosságáról. Ezenfelül a vizsgált eszközök körét (részvényindexek, árupiaci termékek, kriptovaluták, devizapárok) ugyan tudatosan válogattam össze, ám a kevésbé likvid vagy alternatív eszközosztályok (kötvények, opciók, derivatívák) kimaradtak az elemzésből.

A modellek optimalizációs eljárása szintén egyszerűsített grid search alapú megközelítést követett. Bár ez megfelelő kompromisszum a számítási kapacitás és értelmezhetőség között, a legújabb kutatások (autoML, Bayesian tuning, reinforcement learning alapú metakeresés) eredményesebbek lehetnek komplex mély tanulási modellek paramétereinek illesztésében. Továbbá a modellvalidáció „in-sample” és „out-of-sample” bontásra épült, viszont nem került alkalmazásra hagyományos értelemben vett keresztvalidáció, amelyek jobban reflektálna a valódi piaci környezet szekvenciális természetére.

A kereskedési stratégiák szimulációja során nem kerültek beépítésre tranzakciós költségek, likviditási korlátok vagy slippage-effektusok. Ezek a tényezők különösen fontosak lehetnek magas frekvenciájú stratégiák esetén. Emellett az algoritmusok döntéseit predikciós pontosság (MAPE) alapján szűrtem, de nem alkalmaztam explicit bizonytalansági becslést vagy konfidencia intervallum alapú módszereket, amelyek segíthetnének a túlzott pozícionyitások elkerülésében extrém piaci helyzetekben. Szintén egy limitáció, hogy a valós kereskedés során az ajánlati

könyvben szereplő adatok alakulása jelentős hatással van a pozíció nyitásokra és zárásokra, így ez is egy olyan terület, amelyet a jövőben vizsgálni érdemes.

Összességében a disszertáció fontos és új eredményeket hozott a volatilitás hatásának észlelésében és a gépi tanulás kereskedési alkalmazásában, a legmodernebb volatilitás-tudatos architektúrák és adaptív validációs módszerek további lehetőségeket rejtenek magukban. Ezek alkalmazása új dimenziókat nyithat a jövőbeli kutatások számára, különösen a bizonytalanság kezelése és a nemlineáris mintázatok jobb megértése terén.

7. ÚJ TUDOMÁNYOS EREDMÉNYEK

- I. **Igazoltam több különböző terméktípus együttes vizsgálatával (részvények, árupiaci eszközök, devizapárok, kriptovaluták), hogy a volatilitás jelentős hatással van a neurális hálózati modellek előrejelzési teljesítményére (MAPE) függetlenül az alkalmazott módszertantól.**

A kutatás során különböző eszközosztályokat (részvényindexek, árupiaci termékek, devizapárok és kriptovaluták) vizsgáltam meg három különböző időszakban. Az eredmények alapján minden esetben szignifikáns, pozitív kapcsolat mutatkozott a trend- és szezonálismentesített relatív volatilitás és az előrejelzési hiba (MAPE) között. A panel regressziós modellek magas R^2 értékeket mutattak, ami alátámasztja, hogy a volatilitás nemcsak statisztikailag szignifikáns, hanem magyarázó ereje is erős a predikciós teljesítmény változásában. Ez a hatás független volt az eszközosztály típusától és a választott modellarchitektúrától is, vagyis a volatilitás minden esetben torzító tényezőként lép fel.

- II. **Empirikus eszközökkel igazoltam, hogy a piaci volatilitás szintje befolyásolja a modellek közötti teljesítménykülönbséget, mely a magas volatilitású időszakokban érzékelhető.**

A 2018-as (nyugalmi) időszak során az egyes modellek előrejelzési hibái közel azonos tartományban mozogtak. A legtöbb modell (RNN, LSTM, GRU és ezek hibridjei) hasonló MAPE értéket produkált, így a modellválasztás nem volt meghatározó. Az alacsonyabb volatilitású időszakokban a modellek teljesítménye konvergált egymáshoz, csökkentve a modellválasztás jelentőségét. Ezzel szemben a 2020-as válságidőszakban jelentősen megnöttek a modellek közötti különbségek: a predikciós hibák szórása több mint kétszeresére emelkedett. A vizsgálatokból az is kiderült, hogy a magasabb volatilitás szinttel nemcsak a MAPE nő, hanem a teljesítménybeli szórás is, ami különösen fontos tényező a modellalkalmazás során.

- III. **A vizsgált időszakokban a hibrid modellek esetén az első rejtett rétegben alkalmazott RNN architektúra teljesítményrontó hatással bír, függetlenül attól, hogy milyen másik algoritmussal van kombinálva.**

A 2018-as időszak regressziós eredményei alapján egyértelműen kimutatható, hogy az RNN-re épülő hibrid modellek (RNN-GRU vagy RNN-LSTM) magasabb volatilitásérzékenységgel és alacsonyabb predikciós teljesítménnyel jellemezhetők, mint azok a hibrid modellek, amelyek nem tartalmazznak RNN komponenst az első rétegben. Ez

arra utal, hogy az RNN struktúrák nehezebben kezelik a sűrűn zajos, trendfüggő idősorokat, különösen magas volatilitás esetén. Az eredmények továbbá azt mutatják, hogy nem minden modellkombináció jár teljesítménynövekedéssel és a hálózat belső szerkezete különösen az első rétegek felépítése kritikus szerepet játszik a predikciós pontosságban.

IV. Igazoltam, hogy a vizsgált időszakban a GRU-alapú előrejelző modellek kisebb mértékben érzékenyek a relatív volatilitás növekedésére, mint az RNN- vagy LSTM-alapú architektúrák, ami újszerű megközelítést nyújt a modellspecifikáció és piaci bizonytalanság kapcsolatának vizsgálatában.

A disszertációban bemutatott panel regressziós elemzések alapján a relatív volatilitás szignifikáns pozitív kapcsolatban állt az előrejelzési hibával (MAPE), függetlenül az időszaktól és az eszközosztálytól. Ugyanakkor azt is megállapítottam, hogy a volatilitásra adott modellreakció nem egységes: az architektúrák eltérő módon és mértékben torzultak a fokozott piaci bizonytalanság hatására. A GRU-alapú modellek kisebb érzékenységet mutattak, míg az RNN-tartalmú hibrid architektúrák teljesítménye kifejezetten romlott magas volatilitás esetén. Ez az eredmény újszerű módon kombinálja a volatilitási környezet kvantitatív hatását a modellspecifikáció minőségével, és alátámasztja, hogy a predikciós kockázat nemcsak a piac aktuális állapotától, hanem a választott modellstruktúrától is függ. Ezzel lehetővé válik a modellek volatilitásérzékenységi profiljának előzetes elemzése, ami fontos gyakorlati iránymutatás lehet például prediktív kereskedési rendszerek alkalmazásánál. Ez a megállapítás illeszkedik, de tovább is fejleszti a jelenlegi szakirodalom következtetéseit, amelyek külön tárgyalják a volatilitás és modellel való interakciót, de nem vetik össze szisztematikusan különböző architektúrák volatilitás-érzékenységét.

V. Igazoltam, hogy a predikciós hiba (MAPE) dinamikus figyelembevételével kialakított kereskedési szabályok (pozíciónyitás időzítés és a pozícióméretezés) szignifikánsan javítják a kockázat-hozam arányt, különösen a magas volatilitású eszközosztályok esetében. Ez az eredmény empirikus bizonyítékkal szolgál a hatékony piacok hipotézisének gyenge formájának érvényességével szemben.

A kutatás során a kereskedési stratégiák nem csupán a modell által előrejelzett ármozgás irányára épültek, hanem integrálták a becsült előrejelzési hibát (MAPE) is. Ez lehetővé tette, hogy a stratégia két szinten kezelje a bizonytalanságot. Egyrészt kizárta a pozíciónyitást olyan periódusokban, amikor a predikciók megbízhatósága alacsony volt. Másrészt a pozícióméretek dinamikus skálázásával közvetlenül a tőkekitettség szintjén is alkalmazkodott a modellek teljesítményéhez. Az eredmények különösen markánsak voltak

a kriptovalutáknál, ugyanis a Litecoin és Ethereum esetében a maximális drawdown érdemben csökkent, miközben a kumulált hozam és a Sharpe-mutató jelentősen emelkedett a hagyományos buy-and-hold stratégiához képest. Ez a megközelítés új perspektívát kínál a prediktív modellek felhasználásában, mivel nemcsak determinisztikus jeleket használ a kereskedési döntésekhez, hanem a modellek bizonytalanságát is explicit módon beépíti a döntéshozatalba. Ezzel hozzájárul egy adaptív, önreflexióra képes kereskedési architektúra kialakításához, amely érzékenyen reagál a piaci rezsimek változásaira. A gyakorlatban elért teljesítmény pedig arra utal, hogy a predikciós hibák figyelembevétele révén a piac egyes szegmenseiben – különösen a magas volatilitású és információs aszimmetriával jellemezhető eszközosztályoknál – a gyenge formájú hatékony piacok hipotézisével szemben is lehetséges statisztikailag szignifikáns többlethozamot realizálni.

8. ÖSSZEFOGLALÁS

Az összetett és nagyméretű adathalmazok megjelenése jelentős technológiai és szemléletbeli változásokat okozott az előrejelzési modellek fejlesztésében és alkalmazásában, ami az elmúlt 20 évet illeti. A rengeteg adat feldolgozása már nem lenne hatékony a hagyományos módszerekkel, ezért a gépi tanulás elengedhetetlen részévé vált a legtöbb prediktív modellezéssel foglalkozó iparágnak. Különösen igaz ez a pénzügyi szektorra, ahol a profitábilis működés érdekében igyekeznek a rendelkezésre álló innovatív eszközöket a lehető legjobban kihasználni, amelyekre nagy szükség van a nem lineáris összefüggések és mintázatok feltárásához.

A disszertáció két kiemelkedően aktuális és gyakorlati szempontból is jelentős pénzügyi predikciós modellezési problémát vizsgált. Az első célkitűzés a volatilitás predikciós teljesítményre gyakorolt hatásának feltérképezése volt, míg a második a gépi tanuláson alapuló előrejelzéseket hasznosító kereskedési stratégiák hatékonyságát értékelte különböző piaci környezetekben. A kutatás egyaránt támaszkodott kvantitatív regressziós elemzésekre, mélytanulási architektúrák összehasonlítására és visszatesztelt kereskedési stratégiákra, így a disszertáció mind elméleti, mind alkalmazott aspektusokban új tudományos ismeretekkel járult hozzá a pénzügyi gépi tanulási kutatásokhoz. A bevezetésben ismertettem a terület közgazdasági hátterét és jelentőségét, valamint kitértem arra is, hogy milyen fejlődési utat jártak be a prediktív algoritmusok. Továbbá betekintést nyújtottam abba, hogy jelenleg hol tart ez a tudományág és melyek a legújabb trendek. Az általam vizsgált témakör meglehetősen népszerűnek számít a nemzetközi kutatók körében és rengeteg publikáció közül válogathatunk, hogy minél részletesebb képet kaphassunk. A szisztematikus szakirodalmi áttekintést négy fő részre osztottam, amelyekben részletesen foglalkoztam a részvény-, kriptovaluta-, áru- és devizapiacokkal egyaránt. A tudományos publikációk feldolgozása iránymutatással szolgált egyrészt a modellek sajátosságainak megismerésében és megértésében, másrészt a különböző termékspecifikus tényezők azonosításában is. A kutatásom empirikus részében a legnagyobb forgalmú részvényindexek (S&P500, DAX, Nikkei225), árupiaci termékek (nyersolaj - Crude, arany, ezüst), kriptovaluták (Bitcoin, Ethereum, Litecoin) és devizapárok (EUR/USD, GBP/USD, AUD/USD) adatait használtam fel a 2016. január 1. és 2022. június 30. időszakra vonatkozóan. Részben azért erre a periódusra esett a választás, mert itt megtalálható a nyugalmi időszak (2018), a Covid19 (2020) és a háborús krízis (2022) egyaránt, részben pedig azért, mert a kriptovaluták relatíve új terméknek számítanak a többihez képest, így az árfolyamadataik is kisebb időszakot ölelnek fel. Az összehasonlíthatóság szempontjából tehát ez tűnt optimális döntésnek. Az adatokat a www.finance.yahoo.com weboldalról gyűjtöttem össze, kivételt képeznek a kriptovaluták, mert ezek adatai a www.coinmarketcap.com oldalról származnak. A modellezés alapját három mély

tanulási algoritmus képezte (RNN, LSTM, GRU), továbbá az ezekből kialakított szintén három hibrid módszertan (LSTM-GRU, RNN-LSTM, RNN-GRU). A valós és becsült árfolyamok közötti eltéréseket pedig a MAPE mutató segítségével prezentáltam. Az eredmények fejezetet alapvetően három fő részre bontottam. Az elsőben a vizsgált modellek terméktípusonkénti, modellenkénti és időszakonkénti összehasonlítását végeztem el. A módszerek teljesítményelemzése ugyanis nélkülözhetetlen volt a további vizsgálatokhoz, amely a volatilitásra és a valós kereskedési stratégiákra irányult. A dolgozat első célkitűzése annak az összefüggésnek a feltárására irányult a pénzügyi eszközök eltérő volatilitási szerkezete befolyásolja az idősor-alapú gépi tanulási modellek pontosságát. A különböző termékosztályokon (részvények, árupiaci eszközök, kriptovaluták és devizapárok) végzett kísérletek megerősítették, hogy a relatív volatilitás és a predikciós hiba között szoros, pozitív irányú kapcsolat mutatható ki, melyet a különböző architektúrákra futtatott regressziós modellek szignifikánsan alátámasztottak. A kapcsolat minden vizsgált időszakban fennállt, de különösen erősnek bizonyult a 2020-as és 2022-es, válsághelyzetekkel jellemezhető periódusokban. A kutatás másik fontos megállapítása, hogy a modellek teljesítménye erősen időszak- és eszközfüggő. A nyugalmi periódusban (2018) a különbségek minimalizálódtak, míg a válságidőszakokban (2020, 2022) a modellválasztás kritikus tényezővé vált. A hibrid architektúrák (RNN-GRU, LSTM-GRU) a legtöbb esetben jobban teljesítettek, de nem minden kombináció volt előnyös, különösen az RNN első rétegeként való használata rontotta a teljesítményt. A kutatás így közvetlenül igazolta azt a feltételezést, hogy sem a volatilitás, sem a modell architektúra nem kezelhető független tényezőként a predikciós teljesítmény vizsgálata során. A kutatás második célkitűzése annak vizsgálata volt, hogy a gépi tanulási modellekre épített kereskedési stratégiák képesek-e szisztematikusan felülteljesíteni a passzív befektetési megközelítést (buy-and-hold), különösen eltérő volatilitási környezetben. A dolgozat visszatesztelt stratégiákat vizsgált egyenlő súlyozású portfóliókban, három év során (2018, 2020, 2022) és négy különböző eszközosztályon keresztül. A gépi tanulási modellek előrejelzési teljesítményére alapozott módszerek (Alapstratégia, MAPE-szűrő és MAPE-pozíció) konzisztensen javították a hozam és kockázat arányát, amely leginkább a Sharpe-mutató és a drawdown alacsonyabb értékeiben mutatkozott meg. A kriptovaluták esetében a gépi tanulásra épülő stratégiák 2022-ben voltak a legkiemelkedőbbek, miközben a veszteségek jelentősen mérséklődtek. A 2.8 szakirodalmi alfejezetében ismertetett kereskedési stratégiai irodalommal összhangban a dolgozat eredményei azt mutatják, hogy a gépi tanulás nemcsak előrejelzési pontosságot kínál, hanem döntéstámogatási potenciált is hordoz. A különbség ott mutatkozik, hogy a jelen kutatás a stratégiák volatilitás-érzékenységét is explicit módon számszerűsítette, ami új szempontot ad a gépi tanulás alkalmazhatóságának értékeléséhez befektetési környezetben. A stratégiák sikeressége megkérdőjelezi a hatékony piacok elméletének (EMH) gyakorlati

érvényességét, különösen, ha az alkalmazott modellek képesek adaptálódni a piaci rezsimekhez, amit jelen kutatás több ízben bizonyított.

Összességében a dolgozat eredményei hozzájárulnak a gépi tanulási modellek volatilitásérzékenységének megértéséhez és alátámasztják, hogy a prediktív teljesítmény nemcsak a modell struktúrájától, hanem a piaci környezet jellemzőitől is nagymértékben függ. A szakirodalmi háttér alapján kijelenthető, hogy bár számos publikáció foglalkozik a volatilitás előrejelzésével, kevés kutatás elemzi kifejezetten a volatilitás hatását a predikciós teljesítményre, különösen többféle eszközosztályt egyidejűleg vizsgálva. Az előrejelző modellekre alapozott kereskedési stratégiák vizsgálata pedig tovább erősíti a dolgozat gazdasági gyakorlati értékét. A kutatás felhívja a figyelmet a gépi tanulás pénzügyi területen történő felhasználhatóságának sokszínűségére és kiváló eredményeire, valamint hangsúlyozza, hogy a legújabb technológiák alkalmazása elengedhetetlen a folyamatos fejlődés és a rentábilis működés miatt.

9. SUMMARY

The emergence of complex and large data sets has caused significant technological and conceptual changes in the development and application of forecasting models over the past 20 years. Processing the vast amount of data would no longer be efficient using traditional methods, and machine learning has become an essential part of most predictive modelling industries. This is particularly true in the financial sector, where profitable operations seek to make the best use of the innovative tools available, which are much needed to explore non-linear relationships and patterns.

The dissertation examines two highly topical and practically significant financial prediction modeling problems. The first objective was to map the impact of volatility on prediction performance, while the second evaluated the effectiveness of trading strategies utilizing machine learning-based predictions in different market environments. The research relied on quantitative regression analyses, comparisons of deep learning architectures, and back-tested trading strategies, thus contributing new scientific knowledge to financial machine learning research in both theoretical and applied aspects. In the introduction, I presented the economic background and significance of the field, and also discussed the development path of predictive algorithms. Furthermore, I provided insight into the current state of this field of science and the latest trends. The topic I examined is quite popular among international researchers, and there are many publications to choose from to get a more detailed picture. I divided the systematic literature review into four main sections, in which I dealt in detail with the stock, cryptocurrency, commodity, and foreign exchange markets. The analysis of scientific publications provided guidance in understanding the characteristics of the models on the one hand, and in identifying various product-specific factors on the other. In the empirical part of my research, I used data from the most traded stock indices (S&P500, DAX, Nikkei225), commodity market products (crude oil, gold, silver), cryptocurrencies (Bitcoin, Ethereum, Litecoin) and currency pairs (EUR/USD, GBP/USD, AUD/USD) for the period from January 1, 2016 to June 30, 2022. This period was chosen in part because it includes the calm period (2018), the Covid19 (2020) and the war crisis (2022), and partly because cryptocurrencies are relatively new products compared to the others, so their exchange rate data covers a shorter period. Therefore, this seemed to be the optimal decision in terms of comparability. I collected the data from the website www.finance.yahoo.com, with the exception of cryptocurrencies, for which the data comes from www.coinmarketcap.com. The modeling was based on three deep learning algorithms (RNN, LSTM, GRU) and three hybrid methodologies developed from them (LSTM-GRU, RNN-LSTM, RNN-GRU) developed from them. I presented the differences between actual and estimated exchange rates using the MAPE

indicator. I divided the results chapter into three main sections. In the first section, I compared the models examined by product type, model, and period. The performance analysis of the methods was essential for further investigations, which focused on volatility and real trading strategies. The first objective of the thesis was to explore the relationship between the different volatility structures of financial instruments and the accuracy of time series-based machine learning models. Experiments conducted on different product classes (stocks, commodity market instruments, cryptocurrencies, and currency pairs) confirmed that there is a strong positive correlation between relative volatility and prediction error, which was significantly supported by regression models run on different architectures. The relationship was present in all periods examined, but proved to be particularly strong in the crisis periods of 2020 and 2022. Another important finding of the research is that the performance of the models is highly dependent on the period and the asset. During the calm period (2018), the differences were minimized, while during the crisis periods (2020, 2022), model selection became a critical factor. Hybrid architectures (RNN-GRU, LSTM-GRU) performed better in most cases, but not all combinations were beneficial, especially the use of RNN as the first layer, which degraded performance. The research thus directly confirmed the assumption that neither volatility nor model architecture can be treated as independent factors when examining predictive performance. The second objective of the research was to examine whether trading strategies built on machine learning models are capable of systematically outperforming the passive investment approach (buy-and-hold), especially in environments with varying volatility. The paper examined backtested strategies in equally weighted portfolios over three years (2018, 2020, 2022) and across four different asset classes. Methods based on the predictive performance of machine learning models (Base Strategy, MAPE Filter, and MAPE Position) consistently improved the risk-return ratio, which was most evident in lower Sharpe ratios and drawdowns. In the case of cryptocurrencies, machine learning-based strategies were most prominent in 2022, while losses were significantly reduced. In line with the trading strategy literature discussed in Section 2.8, the results of this paper show that machine learning not only offers predictive accuracy but also has decision support potential. The difference is that the present study explicitly quantified the volatility sensitivity of the strategies, which provides a new perspective on the evaluation of the applicability of machine learning in an investment environment. The success of the strategies calls into question the practical validity of the efficient market hypothesis (EMH), especially if the models used are able to adapt to market regimes, as this research has demonstrated on several occasions.

Overall, the results of this paper contribute to the understanding of the volatility sensitivity of machine learning models and support the notion that predictive performance depends not only on the structure of the model but also a large extent on the characteristics of the market environment.

Based on the literature review, it can be stated that although numerous publications deal with volatility forecasting, few studies specifically analyze the impact of volatility on predictive performance, especially when examining multiple asset classes simultaneously. The examination of trading strategies based on predictive models further reinforces the practical economic value of the thesis. The research draws attention to the diversity and excellent results of machine learning in the financial sector and emphasizes that the application of the latest technologies is essential for continuous development and profitable operation.

10. MELLÉKLETEK

M1. Irodalomjegyzék

1. Abedin, M. Z., Moon, M. H., Hassan, M. K., & Hajek, P. (2021). Deep learning-based exchange rate prediction during the COVID-19 pandemic. *Annals of Operations Research*, 1-52. doi: <https://doi.org/10.1007/s10479-021-04420-6>
2. Agorbia-Atta, C., & Atalor, I. (2024). Enhancing anti-money laundering capabilities: The Strategic Use of AI and Cloud Technologies in Financial Crime Prevention. *World Journal of Advanced Research and Reviews*, 23(2), 2035-2047. doi: <https://doi.org/10.30574/wjarr.2024.23.2.2508>
3. Ahern, K. R., & Peress, J. (2023). The role of media in financial decision-making (pp. 192-212). Edward Elgar Publishing. doi: <https://doi.org/10.4337/9781802204179.00019>
4. Ahmed, S., Alshater, M. M., El Ammari, A., & Hammami, H. (2022). Artificial intelligence and machine learning in finance: A bibliometric review. *Research in International Business and Finance*, 61, 101646. doi: <https://doi.org/10.1016/j.ribaf.2022.101646>
5. Ahmed, S., Hassan, S.-U., Aljohani, N. R., & Nawaz, R. (2020). FLF-LSTM: A novel prediction system using Forex Loss Function. *Applied Soft Computing*, 97, 106780. doi: 10.1016/j.asoc.2020.106780
6. Akerlof, G. A. (1978). The market for “lemons”: Quality uncertainty and the market mechanism. In *Uncertainty in economics* (pp. 235-251). Academic Press. doi: <https://doi.org/10.1016/B978-0-12-214850-7.50022-X>
7. Akyildirim, E., Goncu, A., & Sensoy, A. (2021). Prediction of cryptocurrency returns using machine learning. *Annals of Operations Research*, 297(1), 3-36. doi: <https://doi.org/10.1007/s10479-020-03575-y>
8. Alkhodhairi, R. K., Aljalhami, S. R., Rusayni, N. K., Alshobaili, J. F., Al-Shargabi, A. A., & Alabdulatif, A. (2021). Bitcoin Candlestick Prediction with Deep Neural Networks Based on Real Time Data. *CMCCOMPUTERS MATERIALS & CONTINUA*, 68(3), 3215-3233. doi: 10.32604/cmc.2021.016881
9. Al-Nefaie, A. H., & Aldhyani, T. H. (2022). Bitcoin Price Forecasting and Trading: Data Analytics Approaches. *Electronics*, 11(24), 4088. doi: <https://doi.org/10.3390/electronics11244088>
10. Alonso-Monsalve, S., Suárez-Cetrulo, A. L., Cervantes, A., & Quintana, D. (2020). Convolution on neural networks for high-frequency trend prediction of cryptocurrency exchange rates using technical indicators. *Expert Systems with Applications*, 149, 113250. doi: <https://doi.org/10.1016/j.eswa.2020.113250>

11. Alzaman, C. (2023). Forecasting and optimization stock predictions: Varying asset profile, time window, and hyperparameter factors. *Systems and Soft Computing*, 5, 200052. doi: <https://doi.org/10.1016/j.sasc.2023.200052>
12. Apicella, A., Donnarumma, F., Isgrò, F., & Prevete, R. (2021). A survey on modern trainable activation functions. *Neural Networks*, 138, 14-32. doi: <https://doi.org/10.1016/j.neunet.2021.01.026>
13. Araujo, D., Bruno, G., Marcucci, J., Schmidt, R., & Tissot, B. (2023). Machine learning applications in central banking. *Journal of AI, Robotics & Workplace Automation*, 2(3), 271-293.
14. Ardabili, S., Abdolalizadeh, L., Mako, C., Torok, B., & Mosavi, A. (2022). Systematic review of deep learning and machine learning for building energy. *Frontiers in Energy Research*, 10, 1–19. doi: <https://doi.org/10.3389/fenrg.2022.786027>
15. Asawa, Y. S. (2021). Modern machine learning solutions for portfolio selection. *IEEE Engineering Management Review*, 50(1), 94-112. doi: <https://doi.org/10.1016/10.1109/EMR.2021.3131158>
16. Atsalakis, G. S., & Valavanis, K. P. (2009). Surveying stock market forecasting techniques—Part II: Soft computing methods. *Expert Systems with applications*, 36(3), 5932-5941. doi: <https://doi.org/10.1016/j.eswa.2008.07.006>
17. Avinash, G., Ramasubramanian, V., Ray, M., Paul, R. K., Godara, S., Nayak, G. H. H., ... & Iquebal, M. A. (2024). Price Forecasting of TOP (Tomato, Onion and Potato) Commodities using Hidden Markov-based Deep Learning Approach. *Statistics and Applications*, 22(2), 1-28.
18. Ayala, J., García-Torres, M., Noguera, J. L. V., Gómez-Vela, F., & Divina, F. (2021). Technical analysis strategy optimization using a machine learning approach in stock market indices. *Knowledge-Based Systems*, 225, 107119. doi: [10.1016/j.knosys.2021.107119](https://doi.org/10.1016/j.knosys.2021.107119)
19. Aydogan-Kilic, D., & Selcuk-Kestel, A. S. (2023). Modification of hybrid RNN-HMM model in asset pricing: univariate and multivariate cases. *Applied Intelligence*, 53(20), 23812-23833. doi: <https://doi.org/10.1007/s10489-023-04762-7>
20. Baffour, A. A., Jingchun, F., & Taylor, E. K. (2019). A hybrid Artificial Neural Network-GJR modelling approach to forecasting currency exchange rate volatility. *Neurocomputing*. doi: [10.1016/j.neucom.2019.07.088](https://doi.org/10.1016/j.neucom.2019.07.088)
21. Bai, Y., Xie, J., Liu, C., Tao, Y., Zeng, B., & Li, C. (2021). Regression modeling for enterprise electricity consumption: A comparison of recurrent neural network and its

- variants. *International Journal of Electrical Power & Energy Systems*, 126, 106612. doi: <https://doi.org/10.1016/j.ijepes.2020.106612>
22. Bajra, U. Q., Gjeçi, A., & Cadez, S. (2025). At the crossroads of inflation: analyzing Central Bank responses in noneconomic crises. *Studies in Economics and Finance*, 42(3), 468-488. doi: <https://doi.org/10.1108/SEF-04-2024-0246>
 23. 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. doi: <https://doi.org/10.1016/j.eswa.2015.05.013>
 24. Ban, G. Y., El Karoui, N., & Lim, A. E. (2018). Machine learning and portfolio optimization. *Management Science*, 64(3), 1136-1154. doi: <https://doi.org/10.1287/mnsc.2016.2644>
 25. 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. doi: <https://doi.org/10.1016/j.knosys.2021.107994>
 26. Barongo, R. I., & Mbelwa, J. T. (2024). Using machine learning for detecting liquidity risk in banks. *Machine Learning with Applications*, 15, 100511. doi: <https://doi.org/10.1016/j.mlwa.2023.100511>
 27. Bartholdy, J., & Peare, P. (2005). Estimation of expected return: CAPM vs. Fama and French. *International Review of Financial Analysis*, 14(4), 407-427. doi: <https://doi.org/10.1016/j.irfa.2004.10.009>
 28. 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. doi: <https://doi.org/10.1016/j.najef.2018.06.013>
 29. Bee, M., Hambuckers, J., & Trapin, L. (2021). Estimating large losses in insurance analytics and operational risk using the g-and-h distribution. *Quantitative Finance*, 21(7), 1207-1221. doi: <https://doi.org/10.1080/14697688.2020.1849778>
 30. Behera, J., Pasayat, A. K., Behera, H., & Kumar, P. (2023). Prediction based mean-value-at-risk portfolio optimization using machine learning regression algorithms for multi-national stock markets. *Engineering Applications of Artificial Intelligence*, 120, 105843. doi: <https://doi.org/10.1016/j.engappai.2023.105843>
 31. Bejani, M. M., & Ghatee, M. (2021). A systematic review on overfitting control in shallow and deep neural networks. *Artificial Intelligence Review*, 54(8), 6391-6438. doi: <https://doi.org/10.1007/s10462-021-09975-1>

32. Belke, A., Dubova, I., & Osowski, T. (2018). Policy uncertainty and international financial markets: the case of Brexit. *Applied Economics*, 50(34-35), 3752-3770. doi: <https://doi.org/10.1080/00036846.2018.1436152>
33. Beniwal, M., Singh, A., & Kumar, N. (2023). Forecasting long-term stock prices of global indices: A forward-validating Genetic Algorithm optimization approach for Support Vector Regression. *Applied Soft Computing*, 110566. doi: <https://doi.org/10.1016/j.asoc.2023.110566>
34. Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, 191, 192-213. doi: <https://doi.org/10.1016/j.ins.2011.12.028>
35. Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., & Khatri, R. K. (2022). Predicting stock market index using LSTM. *Machine Learning with Applications*, 9, 100320. doi: <https://doi.org/10.1016/j.mlwa.2022.100320>
36. Black, F., & Scholes, M. (1973). The pricing of options and corporate liabilities. *Journal of political economy*, 81(3), 637-654.
37. BODISLAV, D. A., Florina, B. R. A. N., PETRESCU, I. E., & GOMBOȘ, C. C. (2024). The Integration of Machine Learning in Central Banks: Implications and Innovations. *European Journal of Sustainable Development*, 13(4), 23-23. doi: <https://doi.org/10.14207/ejsd>
38. Borges, T. A., & Neves, R. F. (2020). Ensemble of machine learning algorithms for cryptocurrency investment with different data resampling methods. *Applied Soft Computing*, 90, 106187. doi: <https://doi.org/10.1016/j.asoc.2020.106187>
39. Borovkova, S., & Tsiamas, I. (2019). An ensemble of LSTM neural networks for high-frequency stock market classification. *Journal of Forecasting*. doi: 10.1002/for.2585
40. Brockwell, P. J., & Davis, R. A. (Eds.). (2002). *Introduction to time series and forecasting*. New York, NY: Springer New York.
41. Büyüksahin, Ü. Ç., & Ertekin, Ş. (2019). Improving forecasting accuracy of time series data using a new ARIMA-ANN hybrid method and empirical mode decomposition. *Neurocomputing*, 361, 151-163. doi: <https://doi.org/10.1016/j.neucom.2019.05.099>
42. Caldentey, E. P. (2017). Quantitative Easing (QE), Changes in Global Liquidity, and Financial Instability. *International Journal of Political Economy*, 46(2-3), 91–112. doi: 10.1080/08911916.2017.1383695
43. Campbell, J., & Koffi, B. A. (2024). The Role of AI-powered financial analytics in shaping economic policy: A new era for risk management and national growth in the United States.

- World Journal of Advanced Research and Reviews, 23(3), 2816-2825. doi: <https://doi.org/10.30574/wjarr.2024.23.3.2963>
44. Cao, J., Li, Z., & Li, J. (2019). Financial time series forecasting model based on CEEMDAN and LSTM. *Physica A: Statistical Mechanics and its Applications*, 519, 127-139. doi: <https://doi.org/10.1016/j.physa.2018.11.061>
 45. Cao, W., Zhu, W., Wang, W., Demazeau, Y., & Zhang, C. (2020). A Deep Coupled LSTM Approach for USD/CNY Exchange Rate Forecasting. *IEEE Intelligent Systems*, 1–1. doi:10.1109/mis.2020.2977283
 46. Carpinteyro, M., Venegas-Martínez, F., & Aali-Bujari, A. (2021). Modeling precious metal returns through fractional jump-diffusion processes combined with Markov regime-switching stochastic volatility. *Mathematics*, 9(4), 407. doi: <https://doi.org/10.3390/math9040407>
 47. Cavalli, S., & Amoretti, M. (2021). CNN-based multivariate data analysis for bitcoin trend prediction. *Applied Soft Computing*, 101, 107065. doi: 10.1016/j.asoc.2020.107065
 48. Čeperić, E., Žiković, S., & Čeperić, V. (2017). Short-term forecasting of natural gas prices using machine learning and feature selection algorithms. *Energy*, 140, 893–900. doi:10.1016/j.energy.2017.09.026
 49. Chan, T. L., & Hale, N. (2020). Pricing European-type, early-exercise and discrete barrier options using an algorithm for the convolution of Legendre series. *Quantitative Finance*, 20(8), 1307-1324. doi: <https://doi.org/10.1080/14697688.2020.1736612>
 50. Chen, M. Y., & Chen, B. T. (2015). A hybrid fuzzy time series model based on granular computing for stock price forecasting. *Information Sciences*, 294, 227-241. doi: <https://doi.org/10.1016/j.ins.2014.09.038>
 51. Chen, N. F., Roll, R., & Ross, S. A. (1986). Economic forces and the stock market. *Journal of business*, 383-403. doi: <http://dx.doi.org/10.1086/296344>
 52. Chen, W., Xu, H., Jia, L., & Gao, Y. (2021). Machine learning model for Bitcoin exchange rate prediction using economic and technology determinants. *International Journal of Forecasting*, 37(1), 28-43. doi: 10.1016/j.ijforecast.2020.02.008
 53. Chen, Y., & Hao, Y. (2017). A feature weighted support vector machine and K-nearest neighbor algorithm for stock market indices prediction. *Expert Systems with Applications*, 80, 340-355. doi: <https://doi.org/10.1016/j.eswa.2017.02.044>
 54. Chen, Y., & Yi, Z. (2021). Adaptive sparse dropout: Learning the certainty and uncertainty in deep neural networks. *Neurocomputing*, 450, 354-361. doi: <https://doi.org/10.1016/j.neucom.2021.04.047>

55. Chen, Y., Dong, S., Qian, S., & Chung, K. (2024). Impact of oil price volatility and economic policy uncertainty on business investment-Insights from the energy sector. *Heliyon*, 10(5). doi: <https://doi.org/10.1016/j.heliyon.2024.e26533>
56. Chen, Y., Xie, Z., Zhang, W., Xing, R., & Li, Q. (2021). Quantifying the effect of real estate news on Chinese stock movements. *Emerging Markets Finance and Trade*, 57(15), 4185-4210. doi: <https://doi.org/10.1080/1540496X.2019.1695596>
57. Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 112395. doi: 10.1016/j.cam.2019.112395
58. Cheng, C. H., Tsai, M. C., & Chang, C. (2022). A time series model based on deep learning and integrated indicator selection method for forecasting stock prices and evaluating trading profits. *Systems*, 10(6), 243. doi: <https://doi.org/10.3390/systems10060243>
59. Cheung, W. (2010). The black–litterman model explained. *Journal of Asset Management*, 11, 229-243. doi: <https://doi.org/10.1057/jam.2009.28>
60. Chong, E., Han, C., & Park, F. C. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187–205. doi: 10.1016/j.eswa.2017.04.030
61. Chopra, R., & Sharma, G. D. (2021). Application of artificial intelligence in stock market forecasting: a critique, review, and research agenda. *Journal of risk and financial management*, 14(11), 526. doi: <https://doi.org/10.3390/jrfm14110526>
62. Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. (1990). STL: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*, 6(1), 3–73.
63. Cocco, L., Tonelli, R., & Marchesi, M. (2021). Predictions of bitcoin prices through machine learning based frameworks. *PeerJ Computer Science*, 7, e413. doi: <https://doi.org/10.7717/peerj-cs.413>
64. Dai, Y., Zhou, Q., Leng, M., Yang, X., & Wang, Y. (2022). Improving the Bi-LSTM model with XGBoost and attention mechanism: A combined approach for short-term power load prediction. *Applied Soft Computing*, 109632. doi: <https://doi.org/10.1016/j.asoc.2022.109632>
65. Daniel, K., Hirshleifer, D., & Subrahmanyam, A. (1998). Investor Psychology and Security Market Under- and Overreactions. *The Journal of Finance*, 53(6), 1839–1885. doi: 10.1111/0022-1082.00077
66. Danielsson, J. (2011). *Financial risk forecasting: the theory and practice of forecasting market risk with implementation in R and Matlab*. John Wiley & Sons.

67. Dautel, A. J., Härdle, W. K., Lessmann, S., & Seow, H.-V. (2020). Forex exchange rate forecasting using deep recurrent neural networks. *Digital Finance*, 2(1-2), 69–96. doi: 10.1007/s42521-020-00019-x
68. De BOND, W. F. M., & THALER, R. (1985). Does the Stock Market Overreact? *The Journal of Finance*, 40(3), 793–805. doi: 10.1111/j.1540-6261.1985.tb05004.x
69. De Spiegeleer, J., Madan, D. B., Reyners, S., & Schoutens, W. (2018). Machine learning for quantitative finance: fast derivative pricing, hedging and fitting. *Quantitative Finance*, 18(10), 1635-1643. doi: <https://doi.org/10.1080/14697688.2018.1495335>
70. Deepa, S., Alli, A., & Gokila, S. (2021). Machine learning regression model for material synthesis prices prediction in agriculture. *Materials Today: Proceedings*. doi: <https://doi.org/10.1016/j.matpr.2021.04.327>
71. Deina, C., do Amaral Prates, M. H., Alves, C. H. R., Martins, M. S. R., Trojan, F., Stevan Jr, S. L., & Siqueira, H. V. (2022). A methodology for coffee price forecasting based on extreme learning machines. *Information Processing in Agriculture*, 9(4), 556-565. doi: <https://doi.org/10.1016/j.inpa.2021.07.003>
72. Dixon, M. F., Halperin, I., & Bilokon, P. (2020). *Machine learning in finance* (Vol. 1170). New York, NY, USA: Springer International Publishing. doi: <https://doi.org/10.1007/978-3-030-41068-1>
73. Duan, Y., Goodell, J. W., Li, H., & Li, X. (2022). Assessing machine learning for forecasting economic risk: Evidence from an expanded Chinese financial information set. *Finance Research Letters*, 46, 102273. doi: <https://doi.org/10.1016/j.frl.2021.102273>
74. Duarte, J. B. D., Sarmiento, L. H. T., & Juárez, K. J. S. (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. doi: <https://doi.org/10.1016/j.cya.2017.06.014>
75. Dubey, S. R., Singh, S. K., & Chaudhuri, B. B. (2022). Activation functions in deep learning: A comprehensive survey and benchmark. *Neurocomputing*, 503, 92-108. doi: <https://doi.org/10.1016/j.neucom.2022.06.111>
76. Dutta, A., Kumar, S., & Basu, M. (2020). A gated recurrent unit approach to bitcoin price prediction. *Journal of risk and financial management*, 13(2), 23. doi: <https://doi.org/10.3390/jrfm13020023>
77. Echarte Fernández, M. Á., Nández Alonso, S. L., Jorge-Vázquez, J., & Reier Forradellas, R. F. (2021). Central banks' monetary policy in the face of the COVID-19 economic crisis: Monetary stimulus and the emergence of CBDCs. *Sustainability*, 13(8), 4242. doi: <https://doi.org/10.3390/su13084242>

78. Efendi, R., Arbaiy, N., & Deris, M. M. (2018). A new procedure in stock market forecasting based on fuzzy random auto-regression time series model. *Information Sciences*, 441, 113-132. doi: <https://doi.org/10.1016/j.ins.2018.02.016>
79. Elbannan, M. A. (2015). The capital asset pricing model: an overview of the theory. *International Journal of Economics and Finance*, 7(1), 216-228. doi: <http://dx.doi.org/10.5539/ijef.v7n1p216>
80. Escudero, P., Alcocer, W., & Paredes, J. (2021). Recurrent Neural Networks and ARIMA Models for Euro/Dollar Exchange Rate Forecasting. *Applied Sciences*, 11(12), 5658. doi: 10.3390/app11125658
81. Fama, E. F. (1965). Random Walks in Stock Market Prices. *Financial Analysts Journal*, 21(5), 55–59.
82. Fama, E. F. (1965). The behavior of stock-market prices. *The journal of Business*, 38(1), 34-105.
83. Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383. doi: <https://doi.org/10.2307/2325486>
84. Fama, E. F. (1991). Efficient capital markets: II. *The journal of finance*, 46(5), 1575-1617. doi: <https://doi.org/10.1111/j.1540-6261.1991.tb04636.x>
85. Fama, E. F. (1998). Market efficiency, long-term returns, and behavioral finance. *Journal of financial economics*, 49(3), 283-306. doi: [https://doi.org/10.1016/S0304-405X\(98\)00026-9](https://doi.org/10.1016/S0304-405X(98)00026-9)
86. Fama, E. F., & French, K. R. (1992). The cross-section of expected stock returns. *the Journal of Finance*, 47(2), 427-465. doi: <https://doi.org/10.1111/j.1540-6261.1992.tb04398.x>
87. Fama, E. F., & French, K. R. (2004). The capital asset pricing model: Theory and evidence. *Journal of economic perspectives*, 18(3), 25-46. doi: <https://doi.org/10.1257/0895330042162430>
88. Fang, Y., Guan, B., Wu, S., & Heravi, S. (2020). Optimal forecast combination based on ensemble empirical mode decomposition for agricultural commodity futures prices. *Journal of Forecasting*, 39(6), 877-886. doi:10.1002/for.2665
89. Faru, S. H., Waititu, A., & Nderu, L. (2023). A Hybrid Neural Network Model Based on Transfer Learning for Forecasting Forex Market. *Journal of Data Analysis and Information Processing*, 11(2), 103-120. doi: 10.4236/jdaip.2023.112007
90. 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. doi: <https://doi.org/10.1016/j.ejor.2017.11.054>

91. Gao, B. (2022). The use of machine learning combined with data mining technology in financial risk prevention. *Computational economics*, 59(4), 1385-1405. doi: <https://doi.org/10.1007/s10614-021-10101-0>
92. Ghadiri, H., & Hajizadeh, E. (2025). Designing a cryptocurrency trading system with deep reinforcement learning utilizing LSTM neural networks and XGBoost feature selection. *Applied Soft Computing*, 175, 113029. doi: <https://doi.org/10.1016/j.asoc.2025.113029>
93. Ghoddusi, H., Creamer, G. G., & Rafizadeh, N. (2019). Machine learning in energy economics and finance: A review. *Energy Economics*, 81, 709-727. doi: <https://doi.org/10.1016/j.eneco.2019.05.006>
94. Goldstein, I., Spatt, C. S., & Ye, M. (2024). The Next Chapter of Big Data in Finance. *The Review of Financial Studies*, hhae083. doi: <https://doi.org/10.1093/rfs/hhae083>
95. Gómez Martínez, R., Prado Román, M., & Plaza Casado, P. (2019). Big data algorithmic trading systems based on investors' mood. *Journal of Behavioral Finance*, 20(2), 227-238. doi: <https://doi.org/10.1080/15427560.2018.1506786>
96. Goodell, J. W., Kumar, S., Lim, W. M., & Pattnaik, D. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32, 100577. doi: <https://doi.org/10.1016/j.jbef.2021.100577>
97. Goulet Coulombe, P., Leroux, M., Stevanovic, D., & Surprenant, S. (2022). How is machine learning useful for macroeconomic forecasting?. *Journal of Applied Econometrics*, 37(5), 920-964. doi: <https://doi.org/10.1002/jae.2910>
98. Guliyev, H., & Mustafayev, E. (2022). Predicting the changes in the WTI crude oil price dynamics using machine learning models. *Resources Policy*, 77, 102664. doi: <https://doi.org/10.1016/j.resourpol.2022.102664>
99. Gülmez, B. (2023). Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. *Expert Systems with Applications*, 227, 120346. doi: <https://doi.org/10.1016/j.eswa.2023.120346>
100. 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. doi: <https://doi.org/10.1016/j.eswa.2019.112842>
101. Hanauer, M. X., & Kalsbach, T. (2023). Machine learning and the cross-section of emerging market stock returns. *Emerging Markets Review*, 55, 101022. doi: <https://doi.org/10.1016/j.ememar.2023.101022>

102. Harb, E., Bassil, C., Kassamany, T., & Baz, R. (2024). Volatility interdependence between cryptocurrencies, equity, and bond markets. *Computational Economics*, 63(3), 951-981. doi: <https://doi.org/10.1007/s10614-022-10318-7>
103. Harris, R. D., Stoja, E., & Tan, L. (2017). The dynamic Black–Litterman approach to asset allocation. *European Journal of Operational Research*, 259(3), 1085-1096. doi: <https://doi.org/10.1016/j.ejor.2016.11.045>
104. Hasan, M. M., Popp, J., & Oláh, J. (2020). Current landscape and influence of big data on finance. *Journal of Big Data*, 7(1), 21. doi: <https://doi.org/10.1186/s40537-020-00291-z>
105. He, H., Gao, S., Jin, T., Sato, S., & Zhang, X. (2021). A seasonal-trend decomposition-based dendritic neuron model for financial time series prediction. *Applied Soft Computing*, 108, 107488. doi: <https://doi.org/10.1016/j.asoc.2021.107488>
106. Henderson, J. (2024). The Impact of the Russia-Ukraine War on Global Gas Markets. *Current Sustainable/Renewable Energy Reports*, 11(1), 1-9. doi: <https://doi.org/10.1007/s40518-024-00232-x>
107. Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124, 226-251. doi: <https://doi.org/10.1016/j.eswa.2019.01.012>
108. Hirano, K., & Wright, J. H. (2022). Analyzing cross-validation for forecasting with structural instability. *Journal of Econometrics*, 226(1), 139-154. doi: <https://doi.org/10.1016/j.jeconom.2020.10.009>
109. Hiransha, M., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2018). NSE stock market prediction using deep-learning models. *Procedia computer science*, 132, 1351-1362. doi: 10.1016/j.procs.2018.05.050
110. Hoffmann, W. H. (2005). How to manage a portfolio of alliances. *Long range planning*, 38(2), 121-143. doi: <https://doi.org/10.1016/j.lrp.2005.03.001>
111. Hoseinzade, E., & Haratizadeh, S. (2019). CNNpred: CNN-based stock market prediction using a diverse set of variables. *Expert Systems with Applications*, 129, 273-285. doi: <https://doi.org/10.1016/j.eswa.2019.03.029>
112. Houlihan, P., & Creamer, G. G. (2021). Leveraging social media to predict continuation and reversal in asset prices. *Computational Economics*, 57(2), 433-453. doi: <https://doi.org/10.1007/s10614-019-09932-9>
113. Huang, Z., Zhang, Z., Hua, C., Liao, B., & Li, S. (2024). Leveraging enhanced egret swarm optimization algorithm and artificial intelligence-driven prompt strategies for

- portfolio selection. *Scientific Reports*, 14(1), 26681. doi: <https://doi.org/10.1038/s41598-024-77925-2>
114. Hudson, R., Urquhart, A., & Zhang, H. (2020). Political uncertainty and sentiment: Evidence from the impact of Brexit on financial markets. *European economic review*, 129, 103523. doi: <https://doi.org/10.1016/j.euroecorev.2020.103523>
 115. In, S. Y., Rook, D., & Monk, A. (2019). Integrating alternative data (also known as ESG data) in investment decision making. *Global Economic Review*, 48(3), 237-260. doi: <https://doi.org/10.1080/1226508X.2019.1643059>
 116. Inoue, A., Jin, L., & Rossi, B. (2017). Rolling window selection for out-of-sample forecasting with time-varying parameters. *Journal of econometrics*, 196(1), 55-67. doi: <https://doi.org/10.1016/j.jeconom.2016.03.006>
 117. Islam, M. S., & Hossain, E. (2021). Foreign exchange currency rate prediction using a GRU-LSTM hybrid network. *Soft Computing Letters*, 3, 100009. doi: <https://doi.org/10.1016/j.socl.2020.100009>
 118. Ivaşcu, C. F. (2021). Option pricing using machine learning. *Expert Systems with Applications*, 163, 113799. doi: <https://doi.org/10.1016/j.eswa.2020.113799>
 119. Jang, H., & Lee, J. (2017). An empirical study on modeling and prediction of bitcoin prices with bayesian neural networks based on blockchain information. *Ieee Access*, 6, 5427-5437. doi: 10.1109/ACCESS.2017.2779181
 120. Jaquart, P., Dann, D., & Weinhardt, C. (2021). Short-term bitcoin market prediction via machine learning. *The journal of finance and data science*, 7, 45-66. doi: <https://doi.org/10.1016/j.jfds.2021.03.001>
 121. Jegadeesh, N., & Titman, S. (1993). Returns to buying winners and selling losers: Implications for stock market efficiency. *Journal of Finance*, 48(1), 65–91. doi: <https://doi.org/10.1111/j.1540-6261.1993.tb04702.x>
 122. Jiang, J., Wu, L., Zhao, H., Zhu, H., & Zhang, W. (2023). Forecasting movements of stock time series based on hidden state guided deep learning approach. *Information Processing & Management*, 60(3), 103328. doi: <https://doi.org/10.1016/j.ipm.2023.103328>
 123. Jing, L., & Kang, Y. (2024). Automated cryptocurrency trading approach using ensemble deep reinforcement learning: Learn to understand candlesticks. *Expert Systems with Applications*, 237, 121373. doi: <https://doi.org/10.1016/j.eswa.2023.121373>
 124. 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. doi: <https://doi.org/10.1016/j.eswa.2021.115019>

125. Ju, C., Shen, Q., & Ni, X. (2024). Leveraging LSTM Neural Networks for Stock Price Prediction and Trading Strategy Optimization in Financial Markets. *Applied and Computational Engineering*, 112, 47-53. doi: <https://doi.org/10.54254/2755-2721/2024.17906>
126. Jubert de Almeida, B., Ferreira Neves, R., & Horta, N. (2018). Combining Support Vector Machine with Genetic Algorithms to optimize investments in Forex markets with high leverage. *Applied Soft Computing*, 64, 596–613. doi: 10.1016/j.asoc.2017.12.047
127. Kahneman, D., & Tversky, A. (1979). Prospect theory: An analysis of decision under risk. *Econometrica*, 47(2), 363-391.
128. Kang, M., Hong, J., & Kim, S. (2025). Harnessing technical indicators with deep learning based price forecasting for cryptocurrency trading. *Physica A: Statistical Mechanics and its Applications*, 130359. doi: <https://doi.org/10.1016/j.physa.2025.130359>
129. Karanasos, M., Yfanti, S., & Hunter, J. (2022). Emerging stock market volatility and economic fundamentals: The importance of US uncertainty spillovers, financial and health crises. *Annals of operations research*, 313(2), 1077-1116. doi: <https://doi.org/10.1007/s10479-021-04042-y>
130. Khan, H. U., Malik, M. Z., & Nazir, S. (2024). Identifying the AI-based solutions proposed for restricting Money Laundering in Financial Sectors: Systematic Mapping. *Applied Artificial Intelligence*, 38(1), 2344415. doi: <https://doi.org/10.1080/08839514.2024.2344415>
131. 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. doi: <https://doi.org/10.1016/j.eswa.2018.03.002>
132. Kokina, J., Gilleran, R., Blanchette, S., & Stoddard, D. (2021). Accountant as digital innovator: Roles and competencies in the age of automation. *Accounting Horizons*, 35(1), 153-184. doi: <https://doi.org/10.2308/HORIZONS-19-145>
133. Kristjanpoller, W., Fadic, A., & Minutolo, M. C. (2014). Volatility forecast using hybrid neural network models. *Expert Systems with Applications*, 41(5), 2437-2442. doi: <https://doi.org/10.1016/j.eswa.2013.09.043>
134. Kumar, D., Sarangi, P. K., & Verma, R. (2022). A systematic review of stock market prediction using machine learning and statistical techniques. *Materials Today: Proceedings*, 49, 3187-3191. doi: <https://doi.org/10.1016/j.matpr.2020.11.399>
135. Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications*, 197, 116659. doi: <https://doi.org/10.1016/j.eswa.2022.116659>

136. Kute, D. V., Pradhan, B., Shukla, N., & Alamri, A. (2021). Deep learning and explainable artificial intelligence techniques applied for detecting money laundering—a critical review. *IEEE access*, 9, 82300-82317. doi: <https://doi.org/10.1109/ACCESS.2021.3086230>
137. Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons & Fractals*, 118, 35-40. doi: [10.1016/j.chaos.2018.11.014](https://doi.org/10.1016/j.chaos.2018.11.014)
138. Levy, R. A. (1967). Random Walks: Reality or Myth. *Financial Analysts Journal*, 23(6), 69–77. doi: <https://doi.org/10.2469/faj.v23.n6.69>
139. Li, Q., Xu, Z., Shen, X., & Zhong, J. (2021). Predicting business risks of commercial banks based on BP-GA optimized model. *Computational Economics*, 1-19. doi: <https://doi.org/10.1007/s10614-020-10088-0>
140. Li, S., & Xu, S. (2025). Enhancing stock price prediction using GANs and transformer-based attention mechanisms. *Empirical Economics*, 68(1), 373-403. doi: <https://doi.org/10.1007/s00181-024-02644-6>
141. Li, X., & Tang, P. (2020). Stock index prediction based on wavelet transform and FCD-MLGRU. *Journal of Forecasting*, 39(8), 1229-1237. doi: <https://doi.org/10.1002/for.2682>
142. Liang, J., & Jia, G. (2022). China futures price forecasting based on online search and information transfer. *Data Science and Management*, 5(4), 187-198. doi: <https://doi.org/10.1016/j.dsm.2022.09.002>
143. Liang, X., Ge, Z., Sun, L., He, M., & Chen, H. (2019). LSTM with Wavelet Transform Based Data Preprocessing for Stock Price Prediction. *Mathematical Problems in Engineering*, 2019, 1–8. doi:10.1155/2019/1340174
144. Liang, X., Luo, P., Li, X., Wang, X., & Shu, L. (2023). Crude oil price prediction using deep reinforcement learning. *Resources Policy*, 81, 103363. doi: <https://doi.org/10.1016/j.resourpol.2023.103363>
145. Liang, Y., Lin, Y., & Lu, Q. (2022). Forecasting gold price using a novel hybrid model with ICEEMDAN and LSTM-CNN-CBAM. *Expert Systems with Applications*, 206, 117847. doi: <https://doi.org/10.1016/j.eswa.2022.117847>
146. Lim, T. (2024). Environmental, social, and governance (ESG) and artificial intelligence in finance: State-of-the-art and research takeaways. *Artificial Intelligence Review*, 57(4), 76. doi: <https://doi.org/10.1007/s10462-024-10708-3>

147. 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. doi: <https://doi.org/10.3390/su12062451>
148. Lintner, J. (1965). The Valuation of Risk Assets and the Selection of Risky Investments in Stock Portfolios and Capital Budgets. *The Review of Economics and Statistics*, 47(1), 13–37. <https://doi.org/10.2307/1924119>
149. Liu, D., Tang, Z., & Cai, Y. (2022). A Hybrid Model for China's Soybean Spot Price Prediction by Integrating CEEMDAN with Fuzzy Entropy Clustering and CNN-GRU-Attention. *Sustainability*, 14(23), 15522. doi: <https://doi.org/10.3390/su142315522>
150. Liu, K., Zhou, J., & Dong, D. (2021). Improving stock price prediction using the long short-term memory model combined with online social networks. *Journal of Behavioral and Experimental Finance*, 30, 100507. doi: 10.1016/j.jbef.2021.100507
151. Liu, Y. (2019). Novel volatility forecasting using deep learning–long short term memory recurrent neural networks. *Expert Systems with Applications*, 132, 99-109. doi: <https://doi.org/10.1016/j.eswa.2019.04.038>
152. Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*. doi:10.1007/s00521-020-04867-x
153. Lo, A. W. (2004). The Adaptive Markets Hypothesis. *The Journal of Portfolio Management*, 30(5), 15–29. doi: 10.3905/jpm.2004.442611
154. Lo, A. W., & Zhang, R. (2024). *The Adaptive Markets Hypothesis: An Evolutionary Approach to Understanding Financial System Dynamics*. Oxford University Press. doi: <https://doi.org/10.1093/oso/9780199681143.001.0001>
155. Lohrmann, C., & Luukka, P. (2019). Classification of intraday S&P500 returns with a Random Forest. *International Journal of Forecasting*, 35(1), 390-407. Lohrmann, C., & Luukka, P. (2018). Classification of intraday S&P500 returns with a Random Forest. *International Journal of Forecasting*. doi: 10.1016/j.ijforecast.2018.08.004
156. 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*, 106205. doi: 10.1016/j.asoc.2020.106205
157. López de Prado, M. (2019). Beyond econometrics: A roadmap towards financial machine learning. Available at SSRN 3365282. doi: <http://dx.doi.org/10.2139/ssrn.3365282>

158. Luo, A., Zhong, L., Wang, J., Wang, Y., Li, S., & Tai, W. (2024). Short-term stock correlation forecasting based on CNN-BiLSTM enhanced by attention mechanism. IEEE Access. doi: <https://doi.org/10.1109/ACCESS.2024.3369419>
159. Malkiel, B., Mullainathan, S., & Stangle, B. (2005). Market Efficiency versus Behavioral Finance. *Journal of Applied Corporate Finance*, 17(3), 124–136. doi: 10.1111/j.1745-6622.2005.00053.x
160. Mallqui, D. C., & Fernandes, R. A. (2019). Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques. *Applied Soft Computing*, 75, 596-606. doi: 10.1016/j.asoc.2018.11.038
161. Mandala, J., Soehaditama, J. P., Hernawan, M. A., Yulihapsari, I. U., & Sova, M. (2023). Implementing the Capital Asset Pricing Model in Forecasting Stock Returns: A Literature Review. *Indonesian Journal of Business Analytics*, 3(2), 171-182. doi: <https://doi.org/10.55927/ijba.v3i2.3683>
162. Maqsood, H., Mehmood, I., Maqsood, M., Yasir, M., Afzal, S., Aadil, F., ... & Muhammad, K. (2020). A local and global event sentiment based efficient stock exchange forecasting using deep learning. *International Journal of Information Management*, 50, 432-451. doi: <https://doi.org/10.1016/j.ijinfomgt.2019.07.011>
163. Mari, C., & Mari, E. (2023). Deep learning based regime-switching models of energy commodity prices. *Energy Systems*, 14(4), 913-934. doi: <https://doi.org/10.1007/s12667-022-00515-6>
164. Mari, C., & Mari, E. (2025). Stochastic DNN-based models meet hidden Markov models: A challenge on natural gas prices at the Henry Hub. *Neural Computing and Applications*, 1-20. doi: <https://doi.org/10.1007/s00521-025-11286-3>
165. Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77–91. <https://doi.org/10.2307/2975974>
166. Matsunaga, D., Suzumura, T., & Takahashi, T. (2019). Exploring graph neural networks for stock market predictions with rolling window analysis. arXiv preprint arXiv:1909.10660. doi: <https://doi.org/10.48550/arXiv.1909.10660>
167. Md, A. Q., Kapoor, S., AV, C. J., Sivaraman, A. K., Tee, K. F., Sabireen, H., & Janakiraman, N. (2023). Novel optimization approach for stock price forecasting using multi-layered sequential LSTM. *Applied Soft Computing*, 134, 109830. doi: <https://doi.org/10.1016/j.asoc.2022.109830>
168. Merton, R. C. (1973). Theory of rational option pricing. *The Bell Journal of economics and management science*, 141-183. doi: <https://doi.org/10.2307/3003143>

169. Micán, C., Fernandes, G., & Araújo, M. (2020). Project portfolio risk management: a structured literature review with future directions for research. *International Journal of information systems and project management*, 8(3), 67-84. doi: <https://doi.org/10.12821/ijispm080304>
170. Moher, D., Liberati, A., & Altman, D. G. (2009). PRISMA: Preferred Reporting Items for Systematic Reviews and Meta-Analyses. *PLoS med*, 6(7). doi: 10.1371/journal.pmed100097
171. Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Overfitting, model tuning, and evaluation of prediction performance. In *Multivariate statistical machine learning methods for genomic prediction* (pp. 109-139). Cham: Springer International Publishing. doi: https://doi.org/10.1007/978-3-030-89010-0_4
172. Mudassir, M., Bennbaia, S., Unal, D., & Hammoudeh, M. (2020). Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach. *Neural computing and applications*, 1-15. doi: <https://doi.org/10.1007/s00521-020-05129-6>
173. 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. doi: 10.1109/access.2020.3015966
174. Nazareth, N., & Reddy, Y. Y. R. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*, 119640. doi: <https://doi.org/10.1016/j.eswa.2023.119640>
175. Nelson, D. M., Pereira, A. C., & De Oliveira, R. A. (2017, May). Stock market's price movement prediction with LSTM neural networks. In *2017 International joint conference on neural networks (IJCNN)* (pp. 1419-1426). IEEE. doi: 10.1109/IJCNN.2017.7966019
176. Ngo, V. M., Nguyen, H. H., & Van Nguyen, P. (2023). Does reinforcement learning outperform deep learning and traditional portfolio optimization models in frontier and developed financial markets?. *Research in International Business and Finance*, 65, 101936. doi: <https://doi.org/10.1016/j.ribaf.2023.101936>
177. Ni, L., Li, Y., Wang, X., Zhang, J., Yu, J., & Qi, C. (2019). Forecasting of forex time series data based on deep learning. *Procedia computer science*, 147, 647-652. doi: <https://doi.org/10.1016/j.procs.2019.01.189>
178. 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. doi: <https://doi.org/10.1002/isaf.1459>
179. Niu, T., Wang, J., Lu, H. yan, Yang, W., & Du, P. (2020). A Learning System Integrating Temporal Convolution and Deep Learning for Predictive Modeling of Crude Oil Price. *IEEE Transactions on Industrial Informatics*, 1–1. doi:10.1109/tii.2020.3016594
 180. 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), 3007-3057. doi: <https://doi.org/10.1007/s10462-019-09754-z>
 181. Omole, O., & Enke, D. (2024). Deep learning for Bitcoin price direction prediction: models and trading strategies empirically compared. *Financial Innovation*, 10(1), 117. doi: <https://doi.org/10.1186/s40854-024-00643-1>
 182. Ortu, M., Uras, N., Conversano, C., Bartolucci, S., & Destefanis, G. (2022). On technical trading and social media indicators for cryptocurrency price classification through deep learning. *Expert Systems with Applications*, 198, 116804. doi: <https://doi.org/10.1016/j.eswa.2022.116804>
 183. Ouyang, H., Wei, X., & Wu, Q. (2019). Agricultural commodity futures prices prediction via long-and short-term time series network. *Journal of Applied Economics*, 22(1), 468-483. doi: <https://doi.org/10.1080/15140326.2019.1668664>
 184. Ouyang, Z. S., Yang, X. T., & Lai, Y. (2021). Systemic financial risk early warning of financial market in China using Attention-LSTM model. *The North American Journal of Economics and Finance*, 56, 101383. doi: <https://doi.org/10.1016/j.najef.2021.101383>
 185. Oyedele, A. A., Ajayi, A. O., Oyedele, L. O., Bello, S. A., & Jimoh, K. O. (2023). Performance evaluation of deep learning and boosted trees for cryptocurrency closing price prediction. *Expert Systems With Applications*, 213, 119233. doi: <https://doi.org/10.1016/j.eswa.2022.119233>
 186. Ozbayoglu, A. M., Gudelek, M. U., & Sezer, O. B. (2020). Deep learning for financial applications: A survey. *Applied soft computing*, 93, 106384. doi: <https://doi.org/10.1016/j.asoc.2020.106384>
 187. Ozdemir, A. C., Buluş, K., & Zor, K. (2022). Medium-to long-term nickel price forecasting using LSTM and GRU networks. *Resources Policy*, 78, 102906. doi: <https://doi.org/10.1016/j.resourpol.2022.102906>
 188. Patel, M. M., Tanwar, S., Gupta, R., & Kumar, N. (2020). A deep learning-based cryptocurrency price prediction scheme for financial institutions. *Journal of information security and applications*, 55, 102583. doi: <https://doi.org/10.1016/j.jisa.2020.102583>

189. Patel, P. B., & Marwala, T. (2006, October). Forecasting closing price indices using neural networks. In 2006 IEEE international conference on systems, man and cybernetics (Vol. 3, pp. 2351-2356). IEEE. doi: 10.1109/ICSMC.2006.385214
190. Peng, K., & Yan, G. (2021). A survey on deep learning for financial risk prediction. *Quantitative Finance and Economics*, 5(4), 716-737. doi: 10.3934/QFE.2021032
191. Peng, Y., Albuquerque, P. H. M., de Sá, J. M. C., Padula, A. J. A., & Montenegro, M. R. (2018). The best of two worlds: Forecasting high frequency volatility for cryptocurrencies and traditional currencies with Support Vector Regression. *Expert Systems with Applications*, 97, 177-192. doi: 10.1016/j.eswa.2017.12.004
192. Petrini, L., Cagnetta, F., Vanden-Eijnden, E., & Wyart, M. (2023). Learning sparse features can lead to overfitting in neural networks. *Journal of Statistical Mechanics: Theory and Experiment*, 2023(11), 114003. doi: <https://doi.org/0.1088/1742-5468/ad01b9>
193. Pinelis, M., & Ruppert, D. (2022). Machine learning portfolio allocation. *The Journal of Finance and Data Science*, 8, 35-54. doi: <https://doi.org/10.1016/j.jfds.2021.12.001>
194. Poongodi, M., Sharma, A., Vijayakumar, V., Bhardwaj, V., Sharma, A. P., Iqbal, R., & Kumar, R. (2020). Prediction of the price of Ethereum blockchain cryptocurrency in an industrial finance system. *Computers & Electrical Engineering*, 81, 106527. doi: 10.1016/j.compeleceng.2019.106527
195. Pourahmadi, Z., Fareed, D., & Mirzaei, H. R. (2024). A novel stock trading model based on reinforcement learning and technical analysis. *Annals of Data Science*, 11(5), 1653-1674. doi: <https://doi.org/10.1007/s40745-023-00469-1>
196. Qi, L., Khushi, M., & Poon, J. (2020). Event-Driven LSTM For Forex Price Prediction. 2020 IEEE Asia-Pacific Conference on Computer Science and Data Engineering (CSDE). doi: 10.1109/csde50874.2020.9411540
197. Qiu, J., Wang, B., & Zhou, C. (2020). Forecasting stock prices with long-short term memory neural network based on attention mechanism. *PLOS ONE*, 15(1), e0227222. doi: 10.1371/journal.pone.0227222
198. Rather, A. M. (2021). LSTM-based Deep Learning Model for Stock Prediction and Predictive Optimization Model. *EURO Journal on Decision Processes*, 9, 100001. doi: <https://doi.org/10.1016/j.ejdp.2021.100001>
199. 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. doi: <https://doi.org/10.1016/j.epsr.2014.08.006>

200. Ribeiro, M. H. D. M., & dos Santos Coelho, L. (2020). Ensemble approach based on bagging, boosting and stacking for short-term prediction in agribusiness time series. *Applied Soft Computing*, 86, 105837. doi: <https://doi.org/10.1016/j.asoc.2019.105837>
201. RL, M., & Mishra, A. K. (2021). Forecasting spot prices of agricultural commodities in India: Application of deep-learning models. *Intelligent Systems in Accounting, Finance and Management*, 28(1), 72-83. doi: <https://doi.org/10.1002/isaf.1487>
202. Roll, R., & Ross, S. A. (1980). An empirical investigation of the arbitrage pricing theory. *The journal of finance*, 35(5), 1073-1103. doi: <https://doi.org/10.1111/j.1540-6261.1980.tb02197.x>
203. Ross, S. A. (1976). The arbitrage theory of capital asset pricing. *Journal of Economic Theory*, 13(3), 341–360. doi:10.1016/0022-0531(76)90046-6
204. Rouf, N., Malik, M. B., Arif, T., Sharma, S., Singh, S., Aich, S., & Kim, H. C. (2021). Stock market prediction using machine learning techniques: a decade survey on methodologies, recent developments, and future directions. *Electronics*, 10(21), 2717. doi: <https://doi.org/10.3390/electronics10212717>
205. Rundo, F. (2019). Deep LSTM with Reinforcement Learning Layer for Financial Trend Prediction in FX High Frequency Trading Systems. *Applied Sciences*, 9(20), 4460. doi: 10.3390/app9204460
206. Sadefo Kamdem, J., Bandolo Essomba, R., & Njong Berinyuy, J. (2020). Deep learning models for forecasting and analyzing the implications of COVID-19 spread on some commodities markets volatilities. *Chaos, Solitons & Fractals*, 140, 110215. doi: 10.1016/j.chaos.2020.110215
207. Sadeghi, A., Daneshvar, A., & Zaj, M. M. (2021). Combined ensemble multi-class SVM and fuzzy NSGA-II for trend forecasting and trading in Forex markets. *Expert Systems with Applications*, 185, 115566. doi: <https://doi.org/10.1016/j.eswa.2021.115566>
208. Sako, K., Mpinda, B. N., & Rodrigues, P. C. (2022). Neural networks for financial time series forecasting. *Entropy*, 24(5), 657. doi: <https://doi.org/10.3390/e24050657>
209. Salman, S., & Liu, X. (2019). Overfitting mechanism and avoidance in deep neural networks. *arXiv preprint arXiv:1901.06566*. doi: <https://doi.org/10.48550/arXiv.1901.06566>
210. Samuelson, P. A. (1965). Proof That Properly Anticipated Prices Fluctuate Randomly. *Industrial Management Review*, 6 (1), 41-49.

211. Santos, C. F. G. D., & Papa, J. P. (2022). Avoiding overfitting: A survey on regularization methods for convolutional neural networks. *ACM Computing Surveys (CSUR)*, 54(10s), 1-25. doi: <https://doi.org/10.1145/3510413>
212. Satchell, S., & Scowcroft, A. (2007). A demystification of the Black-Litterman model: Managing quantitative and traditional portfolio construction. In *Forecasting expected returns in the financial markets* (pp. 39-53). Academic Press. doi: <https://doi.org/10.1016/B978-075068321-0.50004-2>
213. Sebastião, H., & Godinho, P. (2021). Forecasting and trading cryptocurrencies with machine learning under changing market conditions. *Financial Innovation*, 7(1), 1-30. doi: <https://doi.org/10.1186/s40854-020-00217-x>
214. Sedighi, M., Jahangirnia, H., Gharakhani, M., & Farahani Fard, S. (2019). A novel hybrid model for stock price forecasting based on metaheuristics and support vector machine. *Data*, 4(2), 75. doi: <https://doi.org/10.3390/data4020075>
215. Serrano, W. (2022). The random neural network in price predictions. *Neural Computing and Applications*, 34(2), 855-873. doi: <https://doi.org/10.1007/s00521-021-05903-0>
216. Sezer, O. B., Gudelek, M. U., & Ozbayoglu, A. M. (2020). Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied soft computing*, 90, 106181. doi: <https://doi.org/10.1016/j.asoc.2020.106181>
217. Shah, A., Gor, M., Sagar, M., & Shah, M. (2022). A stock market trading framework based on deep learning architectures. *Multimedia Tools and Applications*, 81(10), 14153-14171. doi: <https://doi.org/10.1007/s11042-022-12328-x>
218. Sharpe, W. F. (1964). Capital asset prices: A theory of market equilibrium under conditions of risk. *The journal of finance*, 19(3), 425-442. doi: <https://doi.org/10.1111/j.1540-6261.1964.tb02865.x>
219. Sharpe, W. F. (1992). Asset allocation: Management style and performance measurement. *Journal of portfolio Management*, 18(2), 7-19.
220. Shi, T., Li, C., Zhang, W., & Zhang, Y. (2023). Forecasting on metal resource spot settlement price: New evidence from the machine learning model. *Resources Policy*, 81, 103360. doi: <https://doi.org/10.1016/j.resourpol.2023.103360>
221. Shi, Y. (2023). Long memory and regime switching in the stochastic volatility modelling. *Annals of Operations Research*, 320(2), 999-1020. doi: <https://doi.org/10.1007/s10479-020-03841-z>

222. Shiller, R. J. (2003). From efficient markets theory to behavioral finance. *Journal of economic perspectives*, 17(1), 83-104. doi: <https://doi.org/10.1257/089533003321164967>
223. Shiller, R. J. (2020). *Narrative economics: How stories go viral and drive major economic events*. Princeton University Press.
224. Shilov, K. D., & Zubarev, A. V. (2021). Evolution of Bitcoin as a financial asset. *Finance: Theory and Practice*, 25(5), 150-171. doi: 10.26794/2587-5671-2021-25-4-150-171
225. Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2018, December). A comparison of ARIMA and LSTM in forecasting time series. In 2018 17th IEEE international conference on machine learning and applications (ICMLA) (pp. 1394-1401). IEEE. doi: 10.1109/ICMLA.2018.00227
226. Singh, B., Patel, S., Vijayvargiya, A., & Kumar, R. (2023). Analyzing the impact of activation functions on the performance of the data-driven gait model. *Results in Engineering*, 18, 101029. doi: <https://doi.org/10.1016/j.rineng.2023.101029>
227. Sivakumar, G. (2025). HMM-LSTM Fusion Model for Economic Forecasting. arXiv preprint arXiv:2501.02002. doi: <https://doi.org/10.48550/arXiv.2501.02002>
228. Skehin, T., Crane, M., & Bezbradica, M. (2018, December). Day ahead forecasting of FAANG stocks using ARIMA, LSTM networks and wavelets. *CEUR Workshop Proceedings*.
229. Song, Y., Lee, J. W., & Lee, J. (2019). A study on novel filtering and relationship between input-features and target-vectors in a deep learning model for stock price prediction. *Applied Intelligence*, 49, 897-911. doi: <https://doi.org/10.1007/s10489-018-1308-x>
230. Stiglitz, J. E. (2000). The contributions of the economics of information to twentieth century economics. *The quarterly journal of economics*, 115(4), 1441-1478. doi: <https://doi.org/10.1162/003355300555015>
231. Sun, X., Liu, M., & Sima, Z. (2020). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*, 32, 101084. doi: 10.1016/j.frl.2018.12.032
232. Sun, Y., Liu, L., Xu, Y., Zeng, X., Shi, Y., Hu, H., ... & Abraham, A. (2024). Alternative data in finance and business: emerging applications and theory analysis. *Financial Innovation*, 10(1), 127. doi: <https://doi.org/10.1186/s40854-024-00652-0>

233. Szandała, T. (2021). Review and comparison of commonly used activation functions for deep neural networks. *Bio-inspired neurocomputing*, 203-224. doi: https://doi.org/10.1007/978-981-15-5495-7_11
234. Tapia, S., & Kristjanpoller, W. (2022). Framework based on multiplicative error and residual analysis to forecast bitcoin intraday-volatility. *Physica A: Statistical Mechanics and its Applications*, 589, 126613. doi: <https://doi.org/10.1016/j.physa.2021.126613>
235. Teng, H. W., & Lee, M. (2019). Estimation procedures of using five alternative machine learning methods for predicting credit card default. *Review of Pacific Basin Financial Markets and Policies*, 22(03), 1950021. doi: <https://doi.org/10.1142/S0219091519500218>
236. Timmermann, A., & Granger, C. W. (2004). Efficient market hypothesis and forecasting. *International Journal of forecasting*, 20(1), 15-27. doi: [https://doi.org/10.1016/S0169-2070\(03\)00012-8](https://doi.org/10.1016/S0169-2070(03)00012-8)
237. Uras, N., Marchesi, L., Marchesi, M., & Tonelli, R. (2020). Forecasting Bitcoin closing price series using linear regression and neural networks models. *PeerJ Computer Science*, 6, e279. doi: <https://doi.org/10.7717/peerj-cs.279>
238. Urolagin, S., Sharma, N., & Datta, T. K. (2021). A combined architecture of multivariate LSTM with Mahalanobis and Z-Score transformations for oil price forecasting. *Energy*, 231, 120963. doi: [10.1016/j.energy.2021.120963](https://doi.org/10.1016/j.energy.2021.120963)
239. Van Horne, J. C., & George G. C. Parker. (1967). The Random-Walk Theory: An Empirical Test. *Financial Analysts Journal*, 23(6), 87–92. doi: <https://doi.org/10.2469/faj.v23.n6.87>
240. Vidal, A., & Kristjanpoller, W. (2020). Gold volatility prediction using a CNN-LSTM approach. *Expert Systems with Applications*, 157, 113481. doi: <https://doi.org/10.1016/j.eswa.2020.113481>
241. Viéitez, A., Santos, M., & Naranjo, R. (2024). Machine learning Ethereum cryptocurrency prediction and knowledge-based investment strategies. *Knowledge-Based Systems*, 299, 112088. doi: <https://doi.org/10.1016/j.knosys.2024.112088>
242. Vu, H. L., Ng, K. T. W., Richter, A., Li, J., & Hosseinipooya, S. A. (2022). Impacts of nested forward validation techniques on machine learning and regression waste disposal time series models. *Ecological Informatics*, 72, 101897. doi: <https://doi.org/10.1016/j.ecoinf.2022.101897>
243. Wall, L. D. (2018). Some financial regulatory implications of artificial intelligence. *Journal of Economics and Business*, 100, 55-63. doi: <https://doi.org/10.1016/j.jeconbus.2018.05.003>

244. Wang, J., Cao, J., Yuan, S., & Cheng, M. (2021). Short-term forecasting of natural gas prices by using a novel hybrid method based on a combination of the CEEMDAN-SE- and the PSO-ALS-optimized GRU network. *Energy*, 233, 121082. doi: 10.1016/j.energy.2021.121082
245. Wang, J., Zhou, H., Hong, T., Li, X., & Wang, S. (2020). A multi-granularity heterogeneous combination approach to crude oil price forecasting. *Energy Economics*, 104790. doi: 10.1016/j.eneco.2020.104790
246. Wang, Y., Li, Y., Song, Y., & Rong, X. (2020). The influence of the activation function in a convolution neural network model of facial expression recognition. *Applied Sciences*, 10(5), 1897. doi: <https://doi.org/10.3390/app10051897>
247. Wang, Y., Wang, C., Sensoy, A., Yao, S., & Cheng, F. (2022). Can Investors' Informed Trading Predict Cryptocurrency Returns? Evidence from Machine Learning. *Research in International Business and Finance*, 101683. doi: <https://doi.org/10.1016/j.ribaf.2022.101683>
248. Wei, L. Y., Chen, T. L., & Ho, T. H. (2011). A hybrid model based on adaptive-network-based fuzzy inference system to forecast Taiwan stock market. *Expert Systems with Applications*, 38(11), 13625-13631. doi: <https://doi.org/10.1016/j.eswa.2011.04.127>
249. Weng, B., Ahmed, M. A., & Megahed, F. M. (2017). Stock market one-day ahead movement prediction using disparate data sources. *Expert Systems with Applications*, 79, 153-163. doi: <https://doi.org/10.1016/j.eswa.2017.02.041>
250. Weng, Y., Wang, X., Hua, J., Wang, H., Kang, M., & Wang, F.-Y. (2019). Forecasting Horticultural Products Price Using ARIMA Model and Neural Network Based on a Large-Scale Data Set Collected by Web Crawler. *IEEE Transactions on Computational Social Systems*, 1–7. doi:10.1109/tcss.2019.2914499
251. White, R., Marinakis, Y., Islam, N., & Walsh, S. (2020). Is Bitcoin a currency, a technology-based product, or something else?. *Technological forecasting and social change*, 151, 119877. doi: <https://doi.org/10.1016/j.techfore.2019.119877>
252. Williams, L. V. (Ed.). (2005). *Information efficiency in financial and betting markets*. Cambridge University Press. doi: <https://doi.org/10.1017/CBO9780511493614.002>
253. Xiao, H., Chen, Z., Cao, R., Cao, Y., Zhao, L., & Zhao, Y. (2022). Prediction of shield machine posture using the GRU algorithm with adaptive boosting: A case study of Chengdu Subway project. *Transportation Geotechnics*, 37, 100837. doi: <https://doi.org/10.1016/j.trgeo.2022.100837>

254. Xie, Z., He, F., Fu, S., Sato, I., Tao, D., & Sugiyama, M. (2021). Artificial neural variability for deep learning: On overfitting, noise memorization, and catastrophic forgetting. *Neural computation*, 33(8), 2163-2192. doi: https://doi.org/10.1162/neco_a_01403
255. Xu, Z., Mohsin, M., Ullah, K., & Ma, X. (2023). Using econometric and machine learning models to forecast crude oil prices: Insights from economic history. *Resources Policy*, 83, 103614. doi: <https://doi.org/10.1016/j.resourpol.2023.103614>
256. Xueling, L., Xiong, X., & Yucong, S. (2023). Exchange rate market trend prediction based on sentiment analysis. *Computers and Electrical Engineering*, 111, 108901. doi: <https://doi.org/10.1016/j.compeleceng.2023.108901>
257. Yao, Y., Zhang, Z. Y., & Zhao, Y. (2023). Stock index forecasting based on multivariate empirical mode decomposition and temporal convolutional networks. *Applied Soft Computing*, 142, 110356. doi: <https://doi.org/10.1016/j.asoc.2023.110356>
258. Yeh, C. Y., Huang, C. W., & Lee, S. J. (2011). A multiple-kernel support vector regression approach for stock market price forecasting. *Expert Systems with Applications*, 38(3), 2177-2186. doi: <https://doi.org/10.1016/j.eswa.2010.08.004>
259. Yıldırım, D. C., Toroslu, I. H., & Fiore, U. (2021). Forecasting directional movement of Forex data using LSTM with technical and macroeconomic indicators. *Financial Innovation*, 7(1). doi: 10.1186/s40854-020-00220-2
260. Yiming, W., Xun, L., Umair, M., & Aizhan, A. (2024). COVID-19 and the transformation of emerging economies: financialization, green bonds, and stock market volatility. *Resources Policy*, 92, 104963. doi: <https://doi.org/10.1016/j.resourpol.2024.104963>
261. Yu, H. (2025). An Adaptive Sharpe Ratio-Based Temporal Fusion Transformer for Financial Forecasting. *Frontiers in Humanities and Social Research*, 2(1), 54-65. doi: <https://doi.org/10.71465/fhsr23>
262. Yu, Y., Lin, Y., Hou, X., & Zhang, X. (2023). Novel optimization approach for realized volatility forecast of stock price index based on deep reinforcement learning model. *Expert Systems with Applications*, 120880. doi: <https://doi.org/10.1016/j.eswa.2023.120880>
263. Zhang, H., Nguyen, H., Vu, D.-A., Bui, X.-N., & Pradhan, B. (2021). Forecasting monthly copper price: A comparative study of various machine learning-based methods. *Resources Policy*, 73, 102189. doi: 10.1016/j.resourpol.2021.102189
264. Zhang, J., Ye, L., & Lai, Y. (2023). Stock price prediction using CNN-BiLSTM-Attention model. *Mathematics*, 11(9), 1985. doi: <https://doi.org/10.3390/math11091985>

265. Zhang, L., Aggarwal, C., & Qi, G.-J. (2017). Stock Price Prediction via Discovering Multi-Frequency Trading Patterns. *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '17*. doi:10.1145/3097983.3098117
266. Zhang, X., & Zhang, T. (2022). Barrier option pricing under a Markov Regime switching diffusion model. *The Quarterly Review of Economics and Finance*, 86, 273-280. doi: <https://doi.org/10.1016/j.qref.2022.08.001>
267. Zhang, Z., Dai, H. N., Zhou, J., Mondal, S. K., García, M. M., & Wang, H. (2021). Forecasting cryptocurrency price using convolutional neural networks with weighted and attentive memory channels. *Expert Systems with Applications*, 183, 115378. doi: <https://doi.org/10.1016/j.eswa.2021.115378>
268. Zhao, L., Li, Z., Qu, L., Zhang, J., & Teng, B. (2023). A hybrid VMD-LSTM/GRU model to predict non-stationary and irregular waves on the east coast of China. *Ocean Engineering*, 276, 114136. doi: <https://doi.org/10.1016/j.oceaneng.2023.114136>
269. Zheng, Y., Luo, J., Chen, J., Chen, Z., & Shang, P. (2023). Natural gas spot price prediction research under the background of Russia-Ukraine conflict-based on FS-GA-SVR hybrid model. *Journal of Environmental Management*, 344, 118446. doi: <https://doi.org/10.1016/j.jenvman.2023.118446>
270. Zhou, C., Huang, Y., Kong, Y., & Lu, X. (2025). Enhancing trading strategies by combining incremental reinforcement learning and self-supervised prediction. *Expert Systems with Applications*, 289, 128297. doi: <https://doi.org/10.1016/j.eswa.2025.128297>
271. Zhu, M. D., Iqbal, J., Nosheen, M., & Ahmed, S. (2025). Investigating the asymmetric effects of exchange rate misalignments on economic growth in Turkey: Insights from threshold effects. *The Journal of International Trade & Economic Development*, 1-35. doi: <https://doi.org/10.1080/09638199.2025.2449879>
272. 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. doi: <https://doi.org/10.1016/j.eswa.2021.115149>
273. Zoumpikas, T., Houstis, E., & Vavalis, M. (2020). Eth analysis and predictions utilizing deep learning. *Expert Systems with Applications*, 162, 113866. doi: <https://doi.org/10.1016/j.eswa.2020.113866>

M2. Ábrajegyzék

1. ábra: A keresés-értékelés szisztematikus grafikon	14
2. ábra: Publikációk száma évenként (n=100)	15
3. ábra: Publikációk megoszlása termékkategóriák szerint (n=100)	16
4. ábra: Publikációk megoszlása idő és a termékkategóriák szerint	17
5. ábra: Top 10 alkalmazott módszertan (n=100)	17
6. ábra: Top 5 teljesítményértékelési mérőszám (n=100)	18
7. ábra: Publikációk megoszlása az adatbázisok hossza alapján (n=100)	19
8. ábra: Publikációk megoszlása statisztikai módszerek szerint (n=100)	19
9. ábra: Megjelent publikációk száma folyóiratok szerint (top 15)	20
10. ábra: Top 5 részvényindex (n=33)	22
11. ábra: Publikációk megoszlása az adatbázisok hossza alapján a részvénypiacok esetében (év) (n=33)	24
12. ábra: Top 10 alkalmazott módszertan a részvénypiacok esetében	25
13. ábra: Top 5 teljesítményértékelési mérőszám a részvénypiacok esetében	26
14. ábra: Top 5 árupiaci termék (n=24)	29
15. ábra: Publikációk megoszlása az adatbázisok hossza alapján az árupiacok esetében (év) (n=24)	31
16. ábra: Top 10 alkalmazott módszertan az árupiacok esetében	33
17. ábra: Top 5 teljesítményértékelési mérőszám az árupiacok esetében	34
18. ábra: Top 5 kriptovaluta (n=27)	36
19. ábra: Publikációk megoszlása az adatbázisok hossza alapján a kriptovaluták esetében (év) (n=27)	38
20. ábra: Top 10 alkalmazott módszertan a kriptovaluták esetében	39
21. ábra: Top 5 teljesítményértékelési mérőszám a kriptovaluták esetében	40
22. ábra: Top 5 devizakereszt (n=16)	42
23. ábra: Publikációk megoszlása az adatbázisok hossza alapján a devizapiacok esetében (év) (n=16)	43
24. ábra: Top 10 alkalmazott módszertan a devizapiacok esetében	44
25. ábra: Top 5 teljesítményértékelési mérőszám a devizapiacok esetében	45
26. ábra: A ReLU, a Sigmoid és a Tanh aktivációs függvények	79
27. ábra: Az S&P500 alakulását, valamint az LSTM (legjobb) és GRU (legrosszabb) egyváltozós modellek előrejelzéseinek alakulást mutatja a nyugalmi időszakra vonatkozóan (2018)	87
28. ábra: Az S&P500 alakulását, valamint az LSTM (legrosszabb) és GRU (legjobb) többváltozós modellek előrejelzéseinek alakulást mutatja a nyugalmi időszakra vonatkozóan (2018)	87
29. ábra: A részvénypiaci előrejelzések MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)	88
30. ábra: A részvénypiaci előrejelzések MAPE mutatói a Covid19 időszakra vonatkozóan (2020)	89
31. ábra: A részvénypiaci előrejelzések MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)	90
32. ábra: A részvénypiaci előrejelzések MAPE mutatóinak átlaga a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018., 2020. és 2022.)	91
33. ábra: Az árupiaci előrejelzések MAPE mutatói nyugalmi időszakra vonatkozóan (2018)	93
34. ábra: Az árupiaci előrejelzések MAPE mutatói a Covid19 időszakra vonatkozóan (2020)	94
35. ábra: Az árupiaci előrejelzések MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)	95
36. ábra: A árupiaci előrejelzések MAPE mutatóinak átlaga a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018., 2020. és 2022.)	96
37. ábra: A kriptovaluta előrejelzések MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)	97
38. ábra: A kriptovaluta előrejelzések MAPE mutatói a Covid19 időszakra vonatkozóan (2020)	98

39. ábra: A kriptovaluta előrejelzések MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)	99
40. ábra: A kriptovaluta előrejelzések MAPE mutatóinak átlaga a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018., 2020. és 2022.)	100
41. ábra: A devizapiaci előrejelzések MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)..	101
42. ábra: A devizapiaci előrejelzések MAPE mutatói a Covid19 időszakra vonatkozóan (2020) ...	102
43. ábra: A devizapiaci előrejelzések MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022)	103
44. ábra: A devizapiaci előrejelzések MAPE mutatóinak a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018., 2020. és 2022.)	104
45. ábra: A vizsgált termékek egyváltozós modelljeinek MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)	105
46. ábra: A vizsgált termékek többváltozós modelljeinek MAPE mutatói a nyugalmi időszakra vonatkozóan (2018)	106
47. ábra: A vizsgált termékek egyváltozós modelljeinek MAPE mutatói a Covid19 időszakra vonatkozóan (2020)	107
48. ábra: A vizsgált termékek többváltozós modelljeinek MAPE mutatói a Covid19 időszakra vonatkozóan (2020)	108
49. ábra: A vizsgált termékek egyváltozós modelljeinek MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022).....	109
50. ábra: A vizsgált termékek többváltozós modelljeinek MAPE mutatói az orosz-ukrán konfliktus időszakára vonatkozóan (2022).....	110
51. ábra: Az alkalmazott egyváltozós modellek össztermékszintű MAPE mutatóinak alakulása a nyugalmi időszakra vonatkozóan (2018).....	111
52. ábra: Az alkalmazott többváltozós modellek össztermékszintű MAPE mutatóinak alakulása a nyugalmi időszakra vonatkozóan (2018).....	112
53. ábra: Az alkalmazott egyváltozós modellek össztermékszintű MAPE mutatóinak alakulása a Covid19 időszakra vonatkozóan (2020).....	113
54. ábra: Az alkalmazott többváltozós modellek össztermékszintű MAPE mutatóinak alakulása a Covid19 időszakra vonatkozóan (2020).....	114
55. ábra: Az alkalmazott egyváltozós modellek össztermékszintű MAPE mutatóinak alakulása az orosz-ukrán konfliktus időszakára vonatkozóan (2022)	115
56. ábra: Az alkalmazott többváltozós modellek össztermékszintű MAPE mutatóinak alakulása az orosz-ukrán konfliktus időszakára vonatkozóan (2022).....	116
57. ábra: A relatív volatilitás és az egyváltozós átlagos MAPE értékek kapcsolata időszakok szerinti megjelenítésben.....	125
58. ábra: A relatív volatilitás és a többváltozós átlagos MAPE értékek kapcsolata időszakok szerinti megjelenítésben.....	126
59. ábra: A 4 kereskedési stratégia összehasonlítása a nyugalmi időszakra vonatkozóan (2018) ...	134
60. ábra: A 4 kereskedési stratégia összehasonlítása a Covid19 időszakra vonatkozóan (2020).....	135
61. ábra: A 4 kereskedési stratégia összehasonlítása az orosz-ukrán konfliktus időszakára vonatkozóan (2022)	137
62. ábra: Azonos súlyozású termékcsopontonkénti portfóliók kumulált féléves hozam a nyugalmi időszakra vonatkozóan (2018).....	138
63. ábra: Azonos súlyozású termékcsopontonkénti portfóliók kumulált féléves hozam a Covid19 időszakra vonatkozóan (2020).....	139
64. ábra: Azonos súlyozású termékcsopontonkénti portfóliók kumulált féléves hozam az orosz-ukrán konfliktus időszakára vonatkozóan (2022)	140
65. ábra: A 12 termékből kialakított azonos súlyozású portfóliók féléves kumulált hozama a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018, 2020 és 2022)	141

M3. Táblázatok jegyzéke

1. táblázat: A felvétel és kizárás minőségi kritériumai.....	13
2. táblázat: A Sharpe-mutatók alakulását bemutató összefoglaló táblázat.....	53
3. táblázat: A vizsgált termékek 2016. január 1. és 2018. június 30. közötti időszakra vonatkozó leíró statisztikái	67
4. táblázat: A vizsgált termékek 2018. január 1. és 2020. június 30. közötti időszakra vonatkozó leíró statisztikái	68
5. táblázat: A vizsgált termékek 2020. január 1. és 2022. június 30. közötti időszakra vonatkozó leíró statisztikái	69
6. táblázat: Az alkalmazott modellek hiperparaméterei	76
7. táblázat: Előrejelzési időhorizontok az egyes időszakokban	77
8. táblázat: A nyugalmi időszak leíró statisztikái (2018. január 1. és 2018. június 30. között).....	84
9. táblázat: A Covid19 időszak leíró statisztikái (2020. január 1. és 2020. június 30. között).....	85
10. táblázat: Az orosz-ukrán konfliktus időszakának leíró statisztikái (2022. január 1. és 2022. június 30. között)	86
11. táblázat: A 2018. január 1. és 2018. június 30. közötti időszak egyváltozós módszerrel becsült MAPE mutatók.....	117
12. táblázat: A 2018. január 1. és 2018. június 30. közötti időszak többváltozós módszerrel becsült MAPE mutatók.....	118
13. táblázat: A 2020. január 1. és 2020. június 30. közötti időszak egyváltozós módszerrel becsült MAPE mutatók.....	118
14. táblázat: A 2020. január 1. és 2020. június 30. közötti időszak többváltozós módszerrel becsült MAPE mutatók.....	119
15. táblázat: A 2022. január 1. és 2022. június 30. közötti időszak egyváltozós módszerrel becsült MAPE mutatók.....	120
16. táblázat: A 2022. január 1. és 2022. június 30. közötti időszak többváltozós módszerrel becsült MAPE mutatók.....	120
17. táblázat: A Litecoin egy- és többváltozós módszerrel becsült MAPE mutatói a különböző aktivációs függvények alkalmazása esetén a 2018. első féléves előrejelzésére vonatkozóan.....	122
18. táblázat: A nyersolaj egy- és többváltozós módszerrel becsült MAPE mutatói a különböző aktivációs függvények alkalmazása esetén a 2020. első féléves előrejelzésére vonatkozóan.....	123
19. táblázat: A Litecoin egy- és többváltozós módszerrel becsült MAPE mutatói a különböző aktivációs függvények alkalmazása esetén a 2022. első féléves előrejelzésére vonatkozóan.....	124
20. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és az egyváltozós MAPE értékeinek regressziós eredményei a nyugalmi időszakra vonatkozóan (2018).....	127
21. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és az egyváltozós MAPE értékeinek regressziós eredményei a Covid19 időszakra vonatkozóan (2020).....	128
22. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és az egyváltozós MAPE értékeinek regressziós eredményei az orosz-ukrán konfliktus időszakra vonatkozóan (2022)	129
23. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és az egyváltozós MAPE értékeinek panel regressziós eredményei az összes időszakra vonatkozóan	131


M4. További mellékletek

1. függelék: az elemzéshez használt termékek log hozamaiból készített korrelációs mátrix a 2016. január 1. és 2022. június 30. közötti időszakra vonatkozóan

	S&P500	DAX	Nikkei225	Nyersolaj	Arany	Ezüst	Bitcoin	Ethereum	Litecoin	EUR/USD	GBP/USD	AUD/USD
S&P500	1											
DAX	0,5895	1										
Nikkei225	0,2130	0,3538	1									
Nyersolaj	0,2680	0,2145	0,1085	1								
Arany	-0,0071	-0,0881	-0,0364	0,0801	1							
Ezüst	0,1208	0,0928	0,0965	0,1598	0,7851	1						
Bitcoin	0,2225	0,1723	0,0214	0,0682	0,0925	0,1174	1					
Ethereum	0,1773	0,1259	0,0313	0,0539	0,0994	0,1102	0,5515	1				
Litecoin	0,2036	0,1565	0,0389	0,0461	0,0535	0,0940	0,6891	0,5487	1			
EUR/USD	0,0479	-0,0002	-0,0051	-0,0060	0,0614	0,0279	-0,0053	0,0071	0,0122	1		
GBP/USD	0,0233	0,0532	0,1592	-0,0108	0,0224	0,0371	-0,0610	-0,0178	-0,0265	0,5617	1	
AUD/USD	0,0396	0,1121	0,2469	0,0314	0,0811	0,0972	-0,0523	-0,0059	-0,0321	0,5163	0,5249	1


Forrás: saját szerkesztés

2. függelék: A vizsgált termékek egy- és többváltozós modelljeinek MAPE mutatói 2018. első félévére vonatkozóan




Forrás: saját szerkesztés

3. függelék: A vizsgált termékek egy- és többváltozós modelljeinek MAPE mutatói 2020. első félévére vonatkozóan



Forrás: saját szerkesztés

4. függelék: A vizsgált termékek egy- és többváltozós modelljeinek MAPE mutatói 2022. első félévére vonatkozóan



Forrás: saját szerkesztés

5. függelék: A modellek futtatásához használt forrásprogram

```
# Time Series Forecasting - Multivariate Time Series Models for Stock Market Prediction

import math # Mathematical functions
import numpy as np # Fundamental package for scientific computing with Python
import pandas as pd # Additional functions for analysing and manipulating data
from datetime import date, timedelta, datetime # Date Functions
from pandas.plotting import register_matplotlib_converters # This function adds
plotting functions for calender dates
import matplotlib.pyplot as plt # Important package for visualization - we use
this to plot the market data
import matplotlib.dates as mdates # Formatting dates
import tensorflow as tf
from sklearn.metrics import mean_absolute_error, mean_squared_error,
mean_absolute_percentage_error, r2_score # Packages for measuring model
performance / errors
from tensorflow.keras import Sequential # Deep learning library, used for neural
networks
from tensorflow.keras.layers import LSTM, Dense, Dropout # Deep learning classes
for recurrent and regular densely-connected layers
from tensorflow.keras.callbacks import EarlyStopping # EarlyStopping during model
training
from sklearn.preprocessing import RobustScaler, MinMaxScaler # This Scaler
removes the median and scales the data according to the quantile range to
normalize the price data
import seaborn as sns # Visualization
sns.set_style('white', { 'axes.spines.right': False, 'axes.spines.top': False})

# check the tensorflow version and the number of available GPUs
print('Tensorflow Version: ' + tf.__version__)
physical_devices = tf.config.list_physical_devices('GPU')
print("Num GPUs:", len(physical_devices))

# Setting the timeframe for the data extraction
end_date = '2022-06-30'#today.strftime("%Y-%m-%d")
start_date = '2020-01-01'

# Getting ticker
stockname = 'S&P500'
symbol = '^GSPC'

# You can either use webreader or yfinance to load the data from yahoo finance
# import pandas_datareader as webreader
# df = webreader.DataReader(symbol, start=start_date, end=end_date,
data_source="yahoo")

import yfinance as yf #Alternative package if webreader does not work: pip
install yfinance
df = yf.download(symbol, start=start_date, end=end_date)
```

```

# Create a quick overview of the dataset
df.head()

# Plot line charts
df_plot = df.copy()

ncols = 2
nrows = int(round(df_plot.shape[1] / ncols, 0))

fig, ax = plt.subplots(nrows=nrows, ncols=ncols, sharex=True, figsize=(14, 7))
for i, ax in enumerate(fig.axes):
    sns.lineplot(data = df_plot.iloc[:, i], ax=ax)
    ax.tick_params(axis="x", rotation=30, labelsize=10, length=0)
    ax.xaxis.set_major_locator(mdates.AutoDateLocator())
fig.tight_layout()
plt.show()

# Indexing Batches
train_df = df.sort_values(by=['Date']).copy()

# List of considered Features
FEATURES = ['High', 'Low', 'Open', 'Close'
            #, 'Month', 'Year', 'Adj Close'
            ]

print('FEATURE LIST')
print([f for f in FEATURES])

# Create the dataset with features and filter the data to the list of FEATURES
data = pd.DataFrame(train_df)
data_filtered = data[FEATURES]

# We add a prediction column and set dummy values to prepare the data for scaling
data_filtered_ext = data_filtered.copy()
data_filtered_ext['Prediction'] = data_filtered_ext['Close']

# Print the tail of the dataframe
data_filtered_ext.tail()

# Get the number of rows in the data
nrows = data_filtered.shape[0]

# Convert the data to numpy values
np_data_unscaled = np.array(data_filtered)
np_data = np.reshape(np_data_unscaled, (nrows, -1))
print(np_data.shape)

# Transform the data by scaling each feature to a range between 0 and 1

```

```

scaler = MinMaxScaler()
np_data_scaled = scaler.fit_transform(np_data_unscaled)

# Creating a separate scaler that works on a single column for scaling
predictions
scaler_pred = MinMaxScaler()
df_Close = pd.DataFrame(data_filtered_ext['Close'])
np_Close_scaled = scaler_pred.fit_transform(df_Close)

# Set the sequence length - this is the timeframe used to make a single
prediction
sequence_length = 50

# Prediction Index
index_Close = data.columns.get_loc("Close")

# Split the training data into train and train data sets
# As a first step, we get the number of rows to train the model on 80% of the
data
train_data_len = math.ceil(np_data_scaled.shape[0] * 0.8)

# Create the training and test data
train_data = np_data_scaled[0:train_data_len, :]
test_data = np_data_scaled[train_data_len - sequence_length:, :]

# The RNN needs data with the format of [samples, time steps, features]
# Here, we create N samples, sequence_length time steps per sample, and 6
features
def partition_dataset(sequence_length, data):
    x, y = [], []
    data_len = data.shape[0]
    for i in range(sequence_length, data_len):
        x.append(data[i-sequence_length:i,:]) #contains sequence_length values 0-
sequence_length * columns
        y.append(data[i, index_Close]) #contains the prediction values for
validation, for single-step prediction

    # Convert the x and y to numpy arrays
    x = np.array(x)
    y = np.array(y)
    return x, y

# Generate training data and test data
x_train, y_train = partition_dataset(sequence_length, train_data)
x_test, y_test = partition_dataset(sequence_length, test_data)

# Print the shapes: the result is: (rows, training_sequence, features)
(prediction value, )
print(x_train.shape, y_train.shape)
print(x_test.shape, y_test.shape)

```

```

# Validate that the prediction value and the input match up
# The last close price of the second input sample should equal the first
prediction value
print(x_train[1][sequence_length-1][index_Close])
print(y_train[0])

# Configure the neural network model
model = Sequential()

# Model with n_neurons = inputshape Timestamps, each with x_train.shape[2]
variables
# n_neurons = x_train.shape[1] * x_train.shape[2]
n_neurons = 150
print(n_neurons, x_train.shape[1], x_train.shape[2])
model.add(LSTM(n_neurons, return_sequences=True, input_shape=(x_train.shape[1],
x_train.shape[2])))
model.add(Dropout(0.01))
model.add(LSTM(n_neurons, return_sequences=True, activation='relu'))
model.add(Dropout(0.01))
model.add(Dense(1))

# Compile the model
model.compile(optimizer='adam', loss='mse')

# Training the model
epochs = 100
batch_size = 16
early_stop = EarlyStopping(monitor='loss', patience=5, verbose=1)
model.summary()
history = model.fit(x_train, y_train,
                    batch_size=batch_size,
                    epochs=epochs,
                    validation_data=(x_test, y_test)
                    )

                    #callbacks=[early_stop])

# Plot training & validation loss values
fig, ax = plt.subplots(figsize=(16, 5), sharex=True)
sns.lineplot(data=history.history["loss"])
plt.title("Model loss")
plt.ylabel("Loss")
plt.xlabel("Epoch")
ax.xaxis.set_major_locator(plt.MaxNLocator(epochs))
plt.legend(["Train", "Test"], loc="upper left")
plt.grid()
plt.show()

```

```

# Get the predicted values
y_pred_scaled = model.predict(x_test)

# Unscale the predicted values
y_pred = scaler_pred.inverse_transform(y_pred_scaled)
y_test_unscaled = scaler_pred.inverse_transform(y_test.reshape(-1, 1))

# Mean Absolute Error (MAE)
MAE = mean_absolute_error(y_test_unscaled, y_pred)
print(f'Mean Absolute Error (MAE): {np.round(MAE, 4)}')

# Mean Squared Error (MSE)
MSE = mean_squared_error(y_test_unscaled, y_pred)
print(f'Mean Squared Error (MSE): {np.round(MSE, 4)}')

# Mean Absolute Percentage Error (MAPE)
MAPE = mean_absolute_percentage_error(y_test_unscaled, y_pred)
print(f'Mean Absolute Percentage Error (MAPE): {np.round(MAPE, 4)}')

# Median Absolute Percentage Error (MDAPE)
MDAPE = np.median((np.abs(np.subtract(y_test_unscaled, y_pred)/ y_test_unscaled))
) * 100
print(f'Median Absolute Percentage Error (MDAPE): {np.round(MDAPE, 4)} %')

# R2 (R2)
R2 = r2_score(y_test_unscaled, y_pred)
print(f'R2 score (R2): {np.round(R2, 4)}')

print('Start date: ' + start_date)
print('End date: ' + end_date)

# The date from which on the date is displayed
display_start_date = "2016-01-01"

# Add the difference between the valid and predicted prices
train = pd.DataFrame(data_filtered_ext['Close'][:train_data_len +
1]).rename(columns={'Close': 'y_train'})
valid =
pd.DataFrame(data_filtered_ext['Close'][train_data_len:]).rename(columns={'Close'
: 'y_test'})
valid.insert(1, "y_pred", y_pred, True)
valid.insert(1, "residuals", valid["y_pred"] - valid["y_test"], True)
df_union = pd.concat([train, valid])

# Zoom in to a closer timeframe
df_union_zoom = df_union[df_union.index > display_start_date]

# Create the lineplot
fig, ax1 = plt.subplots(figsize=(16, 8))
plt.title("y_pred vs y_test")

```



```

plt.ylabel(stockname, fontsize=18)
sns.set_palette(["#090364", "#1960EF", "#EF5919"])
sns.lineplot(data=df_union_zoom[['y_pred', 'y_train', 'y_test']], linewidth=1.0,
dashes=False, ax=ax1)

# Create the bar plot with the differences
df_sub = ["#2BC97A" if x > 0 else "#C92B2B" for x in
df_union_zoom["residuals"].dropna()]
ax1.bar(height=df_union_zoom['residuals'].dropna(),
x=df_union_zoom['residuals'].dropna().index, width=3, label='residuals',
color=df_sub)
plt.legend()
plt.show()

# Excel output
df_union_zoom.to_excel("SP500_LSTM.xlsx")

```

6. függelék: Az alkalmazott kereskedési stratégiához használt forrásprogram

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import os
from itertools import product
!pip install xlswriter

# Elérési utak beállítása
input_file = "Valós_becsült_adatok.xlsx"
output_dir = "results_dynamic_opt"
os.makedirs(output_dir, exist_ok=True)

# Optimalizálható paraméterek
SL_MULTIPLIER_VALUES = [0.5, 1.0, 1.5]
TP_MULTIPLIER_VALUES = [1.5, 2.0, 3.0]
VOL_LOOKBACK_VALUES = [10, 20, 30]

# Összesítő statisztikák
summary_stats = []

# Munkalapok beolvasása
sheet_names = pd.ExcelFile(input_file).sheet_names

def calculate_stats(df):
    stats = {}
    returns = df['Return'].dropna()
    strat_returns = df['Strategy_Return_With_SLTP'].dropna()

    stats['buyHold_Mean'] = returns.mean()
    stats['buyHold_Std'] = returns.std()

```

```

    stats['buyHold_Sharpe'] = returns.mean() / returns.std() *
np.sqrt(252)
    stats['buyHold_Cumulative'] = returns.cumsum().iloc[-1]
    stats['buyHold_Max_Drawdown'] = (returns.cumsum().cummax() -
returns.cumsum()).max()

    stats['Strategy_Mean'] = strat_returns.mean()
    stats['Strategy_Std'] = strat_returns.std()
    stats['Strategy_Sharpe'] = strat_returns.mean() / strat_returns.std()
* np.sqrt(252)
    stats['Strategy_Cumulative'] = strat_returns.cumsum().iloc[-1]
    stats['Strategy_Max_Drawdown'] = (strat_returns.cumsum().cummax() -
strat_returns.cumsum()).max()

    stats['Strategy_Winrate'] = (strat_returns > 0).sum() /
len(strat_returns)
    stats['buyHold_Winrate'] = (returns > 0).sum() / len(returns)

    return stats

def apply_strategy(df, SL_MULTIPLIER, TP_MULTIPLIER, VOL_LOOKBACK):
    df = df.copy()
    df['Position'] = np.where(df['Predicted'].shift(1) >
df['Actual'].shift(1), 1, -1)
    df['Return'] = np.log(df['Actual'] / df['Actual'].shift(1))
    df['Strategy_Return'] = df['Return'] * df['Position']
    df['Volatility'] = df['Return'].rolling(VOL_LOOKBACK).std()
    df['SL'] = SL_MULTIPLIER * df['Volatility']
    df['TP'] = TP_MULTIPLIER * df['Volatility']

    df['Strategy_Return_With_SLTP'] = df['Strategy_Return']
    df.loc[(df['Position'] == 1) & (df['Strategy_Return'] < -df['SL']),
'Strategy_Return_With_SLTP'] = -df['SL']
    df.loc[(df['Position'] == 1) & (df['Strategy_Return'] > df['TP']),
'Strategy_Return_With_SLTP'] = df['TP']
    df.loc[(df['Position'] == -1) & (df['Strategy_Return'] > df['SL']),
'Strategy_Return_With_SLTP'] = df['SL']
    df.loc[(df['Position'] == -1) & (df['Strategy_Return'] < -df['TP']),
'Strategy_Return_With_SLTP'] = -df['TP']

    return df

def run_strategy(sheet_name):
    df = pd.read_excel(input_file, sheet_name=sheet_name)
    df = df.dropna().copy()
    df['Dátum'] = pd.to_datetime(df['Dátum'], errors='coerce')
    df = df.dropna(subset=['Dátum'])
    df.set_index('Dátum', inplace=True)

    actual_candidates = [col for col in df.columns if 'valós' in
col.lower()]

```

```

predicted_candidates = [col for col in df.columns if 'becsült' in
col.lower()]

if not actual_candidates or not predicted_candidates:
    print(f"Skipping {sheet_name}: missing 'valós' or 'becsült'
column.")
    return None

df.rename(columns={actual_candidates[0]: 'Actual',
predicted_candidates[0]: 'Predicted'}, inplace=True)

best_sharpe = -np.inf
best_result = None
best_params = ()

for sl, tp, vol in product(SL_MULTIPLIER_VALUES, TP_MULTIPLIER_VALUES,
VOL_LOOKBACK_VALUES):
    temp_df = apply_strategy(df, sl, tp, vol)
    stats = calculate_stats(temp_df)
    if stats['Strategy_Sharpe'] > best_sharpe:
        best_sharpe = stats['Strategy_Sharpe']
        best_result = temp_df.copy()
        best_stats = stats.copy()
        best_params = (sl, tp, vol)

best_result['Cumulative_Strategy'] =
best_result['Strategy_Return_With_SLTP'].cumsum()
best_result['Cumulative_buyHold'] = best_result['Return'].cumsum()

best_stats['Instrument'] = sheet_name
best_stats['SL_MULTIPLIER'] = best_params[0]
best_stats['TP_MULTIPLIER'] = best_params[1]
best_stats['VOL_LOOKBACK'] = best_params[2]
summary_stats.append(best_stats)

excel_path = os.path.join(output_dir,
f"{sheet_name}_strategy_output.xlsx")
with pd.ExcelWriter(excel_path, engine='xlsxwriter') as writer:
    best_result.to_excel(writer, sheet_name='Data')
    pd.DataFrame([best_stats]).T.rename(columns={0:
'Value'}).to_excel(writer, sheet_name='Stats')

plt.figure(figsize=(10, 5))
plt.plot(best_result.index, best_result['Cumulative_Strategy'],
label=f'Strategy ({best_stats["Strategy_Cumulative"]:.2f})',
color='green')
plt.plot(best_result.index, best_result['Cumulative_buyHold'],
label=f'buy & Hold ({best_stats["buyHold_Cumulative"]:.2f})',
color='blue', linestyle='--')
plt.title(f'Hozamgörbe: {sheet_name}')
plt.xlabel('Dátum')

```

```

plt.ylabel('Kumulált loghozam')
plt.legend()
plt.grid(True)
plt.tight_layout()
plot_path = os.path.join(output_dir,
f"{sheet_name}_strategy_plot.png")
plt.savefig(plot_path)
plt.close()

# Futtatás
results = [run_strategy(sheet) for sheet in sheet_names]
results = [r for r in results if r is not None]

summary_df = pd.DataFrame(summary_stats)
summary_df = summary_df[['Instrument', 'buyHold_Cumulative',
'Strategy_Cumulative',
                        'buyHold_Sharpe', 'Strategy_Sharpe',
                        'buyHold_Max_Drawdown', 'Strategy_Max_Drawdown',
                        'buyHold_Winrate', 'Strategy_Winrate',
                        'SL_MULTIPLIER', 'TP_MULTIPLIER',
'Strategy_VOL_LOOKBACK']]

summary_excel = os.path.join(output_dir, "Összesített_eredmények.xlsx")
summary_df.to_excel(summary_excel, index=False)

plt.figure(figsize=(12, 6))
x = np.arange(len(summary_df))
width = 0.35
plt.bar(x - width/2, summary_df['buyHold_Cumulative'], width, label='buy &
Hold')
plt.bar(x + width/2, summary_df['Strategy_Cumulative'], width,
label='Stratégia (Opt.)')
plt.xticks(x, summary_df['Instrument'], rotation=45)
plt.title("Kumulált hozamok összehasonlítása")
plt.ylabel("Kumulált loghozam")
plt.legend()
plt.tight_layout()
plt.savefig(os.path.join(output_dir, "Összehasonlító_hozamok.png"))
plt.close()

```

7. függelék: A vizsgált termékek relatív volatilitás mutatói STL alapján, valamint az egy- és többváltozós átlagos MAPE értékei

Termék	Évek	CV STL alapján	Egyv. Átl. MAPE	Többv. Átl. MAPE
S&P500	2018	0,0066	0,0110	0,0098
DAX	2018	0,0066	0,0111	0,0106
Nikkei225	2018	0,0077	0,0132	0,0094
Crude oil	2018	0,0108	0,0223	0,0181
Gold	2018	0,0045	0,0085	0,0080
Silver	2018	0,0075	0,0107	0,0117
Bitcoin	2018	0,0357	0,1011	0,0687
Ethereum	2018	0,0475	0,0702	0,0746
Litecoin	2018	0,0432	0,1095	0,1198
EURUSD	2018	0,0032	0,0075	0,0045
GBPUSD	2018	0,0033	0,0047	0,0048
AUDUSD	2018	0,0036	0,0055	0,0038
S&P500	2020	0,0140	0,0197	0,0194
DAX	2020	0,0156	0,0305	0,0298
Nikkei225	2020	0,0150	0,0204	0,0203
Crude oil	2020	0,1005	0,1023	0,1508
Gold	2020	0,0123	0,0202	0,0213
Silver	2020	0,0217	0,0243	0,0264
Bitcoin	2020	0,0277	0,0344	0,0369
Ethereum	2020	0,0341	0,0440	0,0417
Litecoin	2020	0,0374	0,0441	0,0472
EURUSD	2020	0,0042	0,0065	0,0043
GBPUSD	2020	0,0065	0,0075	0,0056
AUDUSD	2020	0,0075	0,0122	0,0104
S&P500	2022	0,0107	0,0172	0,0154
DAX	2022	0,0113	0,0191	0,0206
Nikkei225	2022	0,0092	0,0139	0,0160
Crude oil	2022	0,0268	0,0468	0,0478
Gold	2022	0,0069	0,0097	0,0092
Silver	2022	0,0124	0,0160	0,0173
Bitcoin	2022	0,0248	0,0416	0,0352
Ethereum	2022	0,0294	0,0444	0,0452
Litecoin	2022	0,0326	0,0496	0,0480
EURUSD	2022	0,0039	0,0094	0,0057
GBPUSD	2022	0,0039	0,0063	0,0040
AUDUSD	2022	0,0054	0,0067	0,0052

Forrás: saját szerkesztés

8. függelék: Az alkalmazott kereskedési stratégiák legfontosabb mutatói 2018.01.01. és 2018.06.30. közötti időszakra vonatkozóan

Termék	buy-and- hold kumulált hozam	Alapstratégia kumulált hozam	MAPE- szűrő kumulált hozam	MAPE- pozíció kumulált hozam	buy-and- hold Sharpe	Alapstratégia Sharpe	MAPE- szűrő Sharpe	MAPE- pozíció Sharpe	buy-and- hold Max Drawdown	Alapstratégia Max Drawdown	MAPE- szűrő Max Drawdown	MAPE- pozíció Max Drawdown
S&P500	0,8300	12,4100	14,3200	13,9900	0,1024	2,2722	2,6546	2,6496	0,1071	0,0259	0,0259	0,0258
DAX	-9,1500	3,9700	5,7400	5,9300	-1,0444	0,6700	1,0038	1,0588	0,1787	0,0747	0,0524	0,0520
Nikkei225	-2,0400	-13,5200	-9,1200	-8,8200	-0,2351	-2,0404	-1,4653	-1,4444	0,1571	0,1175	0,1112	0,1106
Nyersolaj	20,5600	16,9400	16,8900	16,2800	1,6850	1,7141	1,7385	1,7154	0,1110	0,0854	0,0759	0,0833
Arany	-4,3000	10,2400	10,6800	10,7100	-0,8045	2,9677	3,1288	3,1859	0,0879	0,0208	0,0208	0,0208
Ezüst	-5,7700	9,5600	10,4000	10,2800	-0,6295	1,3508	1,4735	1,4798	0,0956	0,0585	0,0585	0,0582
Bitcoin	-73,3800	86,7000	23,9100	81,2100	-1,2680	1,7053	1,4161	1,7174	1,0882	0,2862	0,1538	0,2796
Ethereum	-49,7800	81,8900	14,7100	86,3400	-0,7232	1,6031	1,1106	1,8570	1,3274	0,4387	0,1091	0,4310
Litecoin	-102,2400	133,0300	7,0000	102,2000	-1,4056	2,4256	0,8055	2,0923	1,3753	0,3813	0,0888	0,3625
EURUSD	-3,8100	4,2500	4,9900	4,7100	-0,9778	1,4354	1,7211	1,6449	0,0808	0,0228	0,0228	0,0228
GBPUSD	-3,2800	5,7700	5,3000	5,4500	-0,8370	2,1646	2,0508	2,1388	0,0925	0,0301	0,0301	0,0300
AUDUSD	-6,0000	2,9800	2,9100	2,9200	-1,4011	0,8788	0,8640	0,8800	0,1002	0,0447	0,0447	0,0446

Forrás: saját szerkesztés

9. függelék: Az alkalmazott kereskedési stratégiák legfontosabb mutatói 2020.01.01. és 2020.06.30. közötti időszakra vonatkozóan

Termék	buy-and- hold kumulált hozam	Alapstratégia kumulált hozam	MAPE- szűrő kumulált hozam	MAPE- pozíció kumulált hozam	buy-and- hold Sharpe	Alapstratégia Sharpe	MAPE- szűrő Sharpe	MAPE- pozíció Sharpe	buy-and- hold Max Drawdown	Alapstratégia Max Drawdown	MAPE- szűrő Max Drawdown	MAPE- pozíció Max Drawdown
S&P500	-5,6500	74,2600	19,4000	71,5700	-0,2465	4,7055	1,9641	4,7493	0,4144	0,0806	0,0770	0,0802
DAX	-8,4500	29,3600	23,0500	27,3800	-0,3735	1,9352	1,8707	1,8979	0,4943	0,1025	0,1025	0,1004
Nikkei225	-8,4100	9,5800	13,8400	11,7500	-0,5277	0,7751	1,6314	1,0005	0,3750	0,1302	0,1282	0,1268
Nyersolaj	17,1200	-42,6800	-3,7800	-45,5200	0,2734	-0,8190	-0,3043	-1,0159	1,2422	0,8198	0,2318	0,8139
Arany	15,5300	20,3200	21,9200	23,0000	1,3057	2,1189	2,3331	2,4820	0,1253	0,1084	0,1084	0,1083
Ezüst	0,8500	16,0400	17,5700	16,7600	0,0395	1,0985	1,3535	1,0695	0,4749	0,2724	0,2688	0,3593
Bitcoin	24,5000	113,5000	58,4600	104,4800	0,4333	3,2142	2,4315	3,1486	0,7311	0,2516	0,1993	0,2450
Ethereum	56,5700	121,4100	51,6400	111,5700	0,7979	2,8062	2,0883	2,7248	0,9438	0,2079	0,1323	0,2036
Litecoin	1,2300	127,9600	39,0400	106,0600	0,0191	2,7596	1,5478	2,4505	0,9870	0,2914	0,1837	0,2837
EURUSD	0,2100	0,7800	0,4100	0,5000	0,0483	0,2083	0,1119	0,1361	0,0672	0,0703	0,0703	0,0701
GBPUSD	-6,0600	0,3800	0,6300	0,0100	-0,9201	0,0824	0,1413	0,0012	0,1431	0,0780	0,0752	0,0752
AUDUSD	-2,0100	6,0600	4,0400	6,5500	-0,2555	1,0078	0,7165	1,1161	0,2007	0,0624	0,0664	0,0618

Forrás: saját szerkesztés

10. függelék: Az alkalmazott kereskedési stratégiák legfontosabb mutatói 2022.01.01. és 2022.06.30. közötti időszakra vonatkozóan

Termék	buy-and- hold kumulált hozam	Alapstratégia kumulált hozam	MAPE- szűrő kumulált hozam	MAPE- pozíció kumulált hozam	buy-and- hold Sharpe	Alapstratégia Sharpe	MAPE- szűrő Sharpe	MAPE- pozíció Sharpe	buy-and- hold Max Drawdown	Alapstratégia Max Drawdown	MAPE- szűrő Max Drawdown	MAPE- pozíció Max Drawdown
S&P500	-22,4200	13,4900	10,0700	12,7400	-1,8113	1,5703	1,1472	1,4629	0,2686	0,0842	0,0770	0,0770
DAX	-31,1600	7,1100	7,3100	7,1000	-2,0625	0,7339	0,7857	0,7503	0,3328	0,1110	0,1142	0,1114
Nikkei225	-7,5500	18,5500	14,3800	17,0400	-0,7078	2,2776	1,8373	2,1663	0,1712	0,0971	0,0971	0,0960
Nyersolaj	35,4800	-25,0500	10,8900	-26,5300	1,3776	-1,1215	0,7079	-1,2364	0,2715	0,4329	0,2365	0,4272
Arany	0,0600	9,7500	8,7900	8,1700	0,0071	1,3851	1,2736	1,2015	0,1211	0,0605	0,0605	0,0605
Ezüst	-10,8100	14,9400	12,3300	12,4600	-0,7763	1,4722	1,2393	1,2805	0,2631	0,0908	0,0908	0,0904
Bitcoin	-85,3000	25,4100	20,8200	18,7100	-2,0007	0,8781	0,7862	0,6689	0,9193	0,1809	0,1590	0,1774
Ethereum	-121,7700	-1,8000	-26,0400	-0,5700	-2,3158	-0,0502	-1,1571	-0,0165	1,3491	0,3332	0,4469	0,3265
Litecoin	-102,0900	49,0700	0,2200	47,8200	-1,8316	1,3348	0,0120	1,3529	1,2535	0,2324	0,1960	0,2284
EURUSD	-7,6500	7,9100	7,5600	7,3800	-1,7445	2,6046	2,5378	2,5065	0,0988	0,0188	0,0188	0,0188
GBPUSD	-10,2000	0,0800	0,3200	-0,0400	-2,2048	0,0245	0,1022	-0,0140	0,1324	0,0360	0,0325	0,0324
AUDUSD	-5,0100	-1,6600	-3,5800	-3,0200	-0,8594	-0,3739	-0,8196	-0,7005	0,0988	0,0698	0,0698	0,0695

Forrás: saját szerkesztés

11. függelék: Eszközkategóriánkénti azonos súlyozású portfóliók hozama kereskedési stratégia és időszakos bontásban

	buy-and-hold kumulált hozam			Alapstratégia kumulált hozam			MAPE-szűrő kumulált hozam			MAPE-pozíció kumulált hozam		
	2018	2020	2022	2018	2020	2022	2018	2020	2022	2018	2020	2022
Részvény portfólió	-3,45%	-7,51%	-20,38%	0,95%	37,74%	13,05%	3,65%	18,76%	10,59%	3,70%	36,90%	12,29%
Árpiaci portfólió	3,50%	11,17%	8,24%	12,24%	-2,11%	-0,12%	12,66%	11,90%	10,67%	12,42%	-1,92%	-1,97%
Kriptovaluta portfólió	-75,13%	27,43%	-103,05%	100,54%	120,96%	24,23%	15,21%	49,71%	-1,67%	89,91%	107,37%	21,99%
Deviza portfólió	-4,36%	-2,62%	-7,62%	4,34%	2,40%	2,11%	4,40%	1,70%	1,44%	4,36%	2,35%	1,44%

Forrás: saját szerkesztés

KÖSZÖNETNYILVÁNÍTÁS

Köszönetemet szeretném kifejezni témavezetőmnek, Dr. Bareith Tibornak a doktori tanulmányaim alatt nyújtott áldozatos és segítőkész munkájáért, amellyel hozzájárult a dolgozatom elkészítéséhez. Szakmailag és emberileg is példa értékű, amit a közös munka során tapasztaltam.

Köszönöm a segítséget Dr. Tatay Tibornak, aki mindig nyitott volt a közös munkára és értékes szakmai észrevételekkel támogatta a kutatási és publikációs tevékenységem.

Szeretném megköszönni Prof. Dr. Fertő Imrének és Prof. Dr. Kerekes Sándornak, illetve a Kaposvári Campus valamennyi, a doktori programban részt vevő oktatójának az elkötelezett és segítőkész munkáját.

Köszönetemet szeretném kifejezni Dr. Kövér Györgynek a hasznos tanácsai és iránymutatása miatt. Mindig bizalommal fordulhattam hozzá a dolgozatomat érintő kérdésekben.

Köszönettel tartozom édesanyámnak, páromnak, nagymamámnak és kislányomnak Elizának, hogy türelmesen viselték a doktori tanulmányaimmal járó nehézségeket és támogattak.

Szeretnék köszönetet mondani továbbá Laczkó Lórándnének, Móga Zsófiának és Dr. Szabó Kingának a PhD program kiváló koordinálásáért és segítőkész hozzáállásukért.

Értekezésemet édesapámnak, Vancsura Lászlónak ajánlom, aki disszertációm elkészültét sajnos már nem élhette meg, de folyamatosan támogatott a tanulmányaim során. Mindig volt egy bátorító szava, amellyel átsegített a nehézségeken.