

# DOKTORI (PHD) ÉRTEKEZÉS TÉZISEI

Csesznik Zoltán

Gödöllő

2024



Algoritmikus tőzsdei kereskedési rendszerek  
működőképességének elemzése

DOI: 10.54598/002810

Csesznik Zoltán

Gödöllő

2024

## **A doktori iskola**

**Megnevezése:** Gazdaság- és Regionális Tudományok Doktori Iskola

**Tudományága:** Gazdálkodás- és szervezéstudományok

**Vezetője:** Prof. Dr. Bujdosó Zoltán PhD.  
egyetemi tanár

**Témavezetők:** Prof. Dr. Zéman Zoltán, PhD, egyetemi tanár

Dr. habil. Bárczi Judit PhD, egyetemi docens

---

Az iskolavezető  
jóváhagyása

---

A témavezető  
jóváhagyása

---

A témavezető  
jóváhagyása

## **Tartalomjegyzék**

1. A MUNKA ELŐZMÉNYEI, CÉLKITŰZÉSEK.....	5
1.1 A kutatás hipotézisei, célkitűzései.....	6
2. ANYAG ÉS MÓDSZERTAN .....	8
2.1. A kutatás során alkalmazott gépi rendszerépítési modell meghatározása .	8
2.2. A tradicionális befektetési modell módszertana.....	16
2.3. Egyszerű stratégia modell.....	17
3. KUTATÁSI EREDMÉNYEK .....	19
3.1. A gépi modell eredményei.....	19
3.2. A tradicionális modell és eredményei .....	25
3.3. Egyszerű kereskedési modell eredményei .....	27
4. KÖVETKEZTETÉSEK, JAVASLATOK .....	29
5. ÚJ ÉS ÚJSZERŰ TUDOMÁNYOS EREDMÉNYEK.....	31
6. A SZERZŐNEK AZ ÉRTEKEZÉS TÉMAKÖRÉHEZ KAPCSOLÓDÓ PUBLIKÁCIÓI .....	33
7. FELHASZNÁLT IRODALOM .....	36

## 1. A MUNKA ELŐZMÉNYEI, CÉLKITŰZÉSEK

A pénzügyi piacokkal 1999-ben, az első diplomám megszerzése után kerültem kapcsolatba. Az azóta eltelt csaknem negyedszázad evolúcióját áttekintve a világ emberi léptékkal szinte felfoghatatlan technológiai fejlődésen ment keresztül. Ugyanakkor a tőzsdei kereskedés esszenciája, a spekuláció, a profit iránti vágy az évezredek során nem változott és ma is dominálja a pénzügyi piacokat. A területen eltöltött éveim alatt minden egyes nap kihívás volt, sok éven át konzisztensen próbáltam megbecsülni az ismeretlent, vagy kiszámolni a kiszámíthatatlant.

A tőzsdei kereskedés az elmúlt öt évben újra reneszánszát élte és éli köszönhetően a technológiai innovációnak, jogi harmonizációnak (Aslam és mtsai., 2023). A sok millió új belépő egyik fő motivációja, hogy fiatalassák pénzüket, lehetőleg minél többet és gyorsabban. A világ ebben a tekintetben nem változott. Az emberek a tőzsdére mindig is túlaradó várakozásokkal tekintettek, tőle remélték anyagi függetlenségüket és gazdagodásukat (Nassar, 2006). Legtöbbünk természetünkönél fogva könnyen manipulálhatóak vagyunk és átadjuk magunkat azoknak a vágyainknak, hogy megszokott irodai életünket elcserélhessük az önállóságra, függetlenségre. Nassar (2006) szerint a valóság azonban ennél sokkal árnyaltabb és az internet pedig remek táptalajt biztosít a városi legendák terjesztéséhez.

A kereskedés motivációja nagyon sokrétű, történhet befektetési céllal, lehet spekulatív vagy akár lehet céltalan is (Fry-McKibbin & McKinnon, 2023).

Disszertációm a spekulatív kereskedéssel foglalkozik, azon belül is a számítógépes algoritmusok által vezérelt stratégiák létrejöttével, elemzésével, végrehajtásával és megbízhatóságával.

Véleményem szerint a sikeres kereskedéshez meg kell találni az árfolyamban azokat a mintákat, melyek periodikusan ismétlődnek, és melyek kimenetele hasonló (Chen & Tsai, 2020).

## 1.1 A kutatás hipotézisei, célkitűzései

Szakmai munkám során megtapasztaltam a nemzetközi tőzsdei világ működését, a pénzügyi eszközök létrejöttének a folyamatát, a részvényekkel és határidős ügyletekkel való kereskedés szinte összes nüanszát. Megismertem a pénzügyi alapok publikus és kevésbé publikus működési mechanizmusait, struktúrájukat, jogi környezetük hátterét.

C1: A téma sokrétűségéből adódóan rendszerezni fogom a szakirodalmat. Összegyűjtöm és bemutatom az egymásnak ellentmondó tudományos irányvonalakat, elméleteket. Az irodalmi feldolgozás során nagy hangsúlyt fogok fektetni arra, hogy az olyan mértékű és irányú legyen, hogy segítse a pénzügyi piacok működésének megértését.

C2: Kutatásom során rávilágítok az alkalmazható módszerekre, összefoglalom azok legfontosabb tudnivalóit, illetve azok hatékonyságát. Meghatározom az adott eszközön alkalmazandó indikátorok hatékonyságát, az optimális kereskedési időszávokat.

C3: Célom egy olyan diverzifikált kereskedési modell felállítása és elkészítése, mellyel hosszú távon sikeresen lehet kereskedni. Ebben kutatásaim alapján fejlesztett genetikai algoritmusok által generált programkódokat fogok használni.

C4: Célom a modellt alkotó algoritmusok tesztelése, validálása statisztikai módszerekkel. Továbbá megvizsgálom az ezekből felépülő portfólió hosszú távú nyereséges működését.

Kutatásom célkitűzéseinek és hipotéziseinek megfogalmazása során a szakirodalomban leírtakra támaszkodtam, ugyanakkor felhasználtam az elmúlt két évtized során a pénzügyi világban megszerzett ismereteimet, tapasztalataimat.

H1A: A tradicionális befektetési modell – megvesz és tart – alkalmazásával sikeresebben lehet kereskedni a határidős piacokon, mint egy felépített kereskedési algoritmus alkalmazásával.

H1B: A gépi modell által alkotott algoritmusokkal nyereségesebben lehet kereskedni, mint egy egyszerű, általánosan ismert stratégiával (mozgóátlag keresztezés).

H2A: Meghatározható egy olyan indikátor- és paraméterkészlet, ami alapján a számítógép vezérelt algoritmikus modell hosszú távon sikeresen tud kereskedni.

H2B: Bizonyítható, hogy az adott piacon jobban teljesítő indikátorokon alapuló rendszerek összesített teljesítménye nagyobb lesz, mint az összes indikátor segítségével generált rendszerek összesített teljesítménye.

H3: Igazolható, hogy a különböző indikátorokon alapuló diverzifikált rendszerek összesített, mintán kívüli kereskedési eredménye kiegyensúlyozottabb, mint egy-egy rendszer különálló eredménye.

## 2. ANYAG ÉS MÓDSZERTAN

Az alábbiakban részletezem a kutatás során alkalmazott módszertanomat, melyet három fejezetre bontok. Az első fejezet a gépi modellépítés folyamatát részletezi, míg a második fejezet a tradicionális befektetési modell – megvesz és tart – kidolgozását foglalja magába. A harmadik részben pedig egy egyszerű és általánosan ismert stratégiát mutatok be.

### 2.1. A kutatás során alkalmazott gépi rendszerépítési modell meghatározása

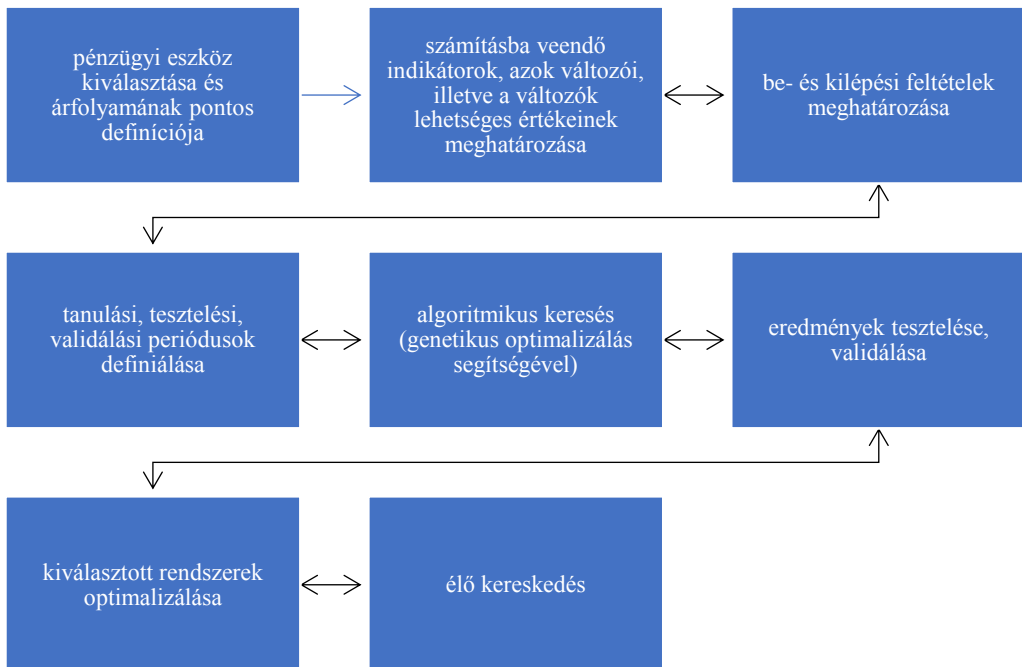
A mesterséges intelligencia (MI) napjainkban izgalomban tartja mind a tudományos világot, mind pedig az átlagembereket. Rengeteget hallani, hogy az MI az élet minden területére beférkőzik. Az igazság az, hogy az MI már az 1950-es évek óta velünk van, felhasználási területei, fejlettsége folyamatosan változik (Huang és mtsai., 2020). A gépi tanulás és a mély tanulás a mesterséges intelligencia részterületei. Az MI rendszerek előrejelzéseket vagy osztályozásokat készítenek a bemeneti adatok alapján (Kühl és mtsai., 2022).

A mesterséges intelligenciának tőzsdei kereskedésben betöltött szerepe az előre definiált szisztematikus algoritmusok végrehajtásában van, illetve hatékonyan lehet használni komplex adatfeldolgozási feladatok hatékony végrehajtására, ez egybeesik a komplex gépi rendszerépítés célkitűzéseivel, melynek során nagyszámú kombinációból kell kiválasztani azokat a modelleket, melyek jövőbeli, ismeretlen árfolyamadatokon is képesek a múltbélihez hasonló profitot generálni (Kühl és mtsai., 2022). Ennek a célnak az elérésére megfelelnek a keskeny mesterséges intelligencia rendszerek (ANI), melyeket egy adott feladat végrehajtására fejlesztettek ki. Ezen rendszerek robusztusok és nagyon hatékonyan tudnak nagy adattömegekkel dolgozni, így kiválasztani számunkra olyan kereskedési algoritmusokat, melyek a jövőben profitot fognak generálni



(Kühl és mtsai., 2022). Természetesen az MI rendszereket hatékonyan lehet alkalmazni a kereskedési algoritmusok tesztelésében, validálásában, kiválasztásában is. A portfólió összeállításában is használhatóak, hiszen sokkal gyorsabban és hatékonyabban dolgozzák fel az adatokat.

A jelenleg rendelkezésre álló számítási kapacitásunkkal képtelenség lenne minden egyes kombinációt végig szimulálni és az eredményeket sorba állítani. Ilyen nagyszámú kombináció esetén hatékony keresési algoritmusokat használunk, melyekkel ugyan nem nézünk végig minden egyes esetet, tehát nem lehetünk benne biztosak, hogy megtaláltuk a globális optimumot, ugyanakkor ezen genetikusan optimalizált algoritmusok által biztosított eredmények jónak minősülnek és megfelelően nagy generációt és populációt választva biztosan elmondhatjuk, hogy globális optimumhoz közelítő eredményeket kapunk (Nicholls & Engelbrecht, 2019).



1. ábra: A rendszerépítés legfontosabb aspektusai

*Forrás: Genetic System Builder, saját szerkesztés*

A 1. ábra a rendszerépítés legfontosabb lépéseit mutatja be. Természetesen amennyiben az adott lépésnél a kapott eredmények nem kielégítőek, a lépést a megfelelő módosítások megtétele után meg kell ismételni.

Ugyan gépi modellépítéssel sokan és sokféleképpen foglalkoztak és számos irodalomban fellelhető folyamatok, mégis a rendszerépítés egyediségét adja, hogy a részfolyamatok felcserélhetőek, illetve azok paramétereinek, rendszerezési módjainak megváltoztatása új, illetve újszerű eredményeket biztosít a kutatók számára. Újszerű eredménynek tekinthető, ha egy adott módszertan alapján sikerül nyereséges rendszereket kifejleszteni. A folyamatot, illetve a lépéseket a szakirodalom alapján alakítottam ki, ugyanakkor azok sorrendjét és a változóit saját magam határoztam meg.

A. Piacok meghatározása: Bármely likvid pénzügyi piacra (eszközre) építhetők bizonyos határfokkal kereskedési rendszerek, disszertációmban árutőzsdei határidős piacokra fókuszálok. Ennek egyik oka, a személyes preferencia. Úgy gondolom, hogy mivel ezek a piacok kisebbek, a sok milliárd dolláros alapok és befektetési bankok számára kevésbé érdekesek, tehát a spekulációs kereslet kisebb. Ugyanakkor a fedezeti kereskedők jól definiálható és látható szezonális igényekkel jelentkeznek ezeken a piacokon, így a gyakrabban előforduló árfolyamminták jobban definiálhatóak. Az eszközök kiválasztásánál figyelembe veszem azt, hogy azok egymástól függetlenek legyenek, adott termék gazdasági és politikai eseményei minimális befolyással legyenek a másik termékre, továbbá, hogy a geopolitikai események is alacsonyabb súllyal kerüljenek számításba a kereskedés során. Stabil, sok évtizede létező piacok legyenek, melyek lehetővé teszik a megfelelő elemzést a historikus adatok segítségével. További szempont volt, hogy a napi kereskedési idő rövid legyen, mely a gyorsabb elemzést teszi lehetővé. A fentiek alapján a következő határidős szerződéseket választom ki:

- Sovány sertés (LH)
- Búza (W)
- Kávészemek (KC)

- Fagyasztott narancslé (OJ)

B. Portfólió meghatározása: A portfólió piaconként legfeljebb a nyolc legjobb rendszerből épül fel, figyelembe véve az A) pontot összesen maximum 32 rendszerünk lesz. Ez biztosítani fogja a diverzifikációt és elvárásunk, hogy a rendszerek korrelációja alacsony legyen.

C. Adatbázis meghatározása: Jelenti azon adatok összességét, melyeket felhasználunk a kutatás során. A Globális adatbázis: 2010.01.01-2023.09.01. tartalmazza az A) pontban meghatározott piacok adatait. Az adatbázisunkat az alábbi időszakokra osztjuk fel:

- Tréning időszak: 2010.01.01. – 2021.12.31. nyolcvan napos kihagyásokkal
- Teszt időszak: 2010.01.01. – 2021.12.31. nyolcvan napos kihagyásokkal.
- Validációs időszak: 2022.01.01. – 2023.09.01.

A tréning (mintán belüli) és a teszt (mintán kívüli) időszakok egymást nyolcvan naponta váltják. Ennek jelentősége, hogy a rendszer betanításához az adatbázis minden részéből használunk adatokat, beleértve legutóbbi árfolyamot is. Így mind a tréning, mind pedig a teszt időszakokban az árfolyamkarakterisztikák sokrétűek. A validációs időszak célja, hogy miután a portfóliót összeállítottuk ezen az adathalmazon szimuláljuk az éles kereskedést.

Adatszerkezet definiálása: Az alapadatok időbeli rendszerezése 30 perces nyitó-magas-alacsony-záró elv alapján történik, míg a verifikációs adatszerkezet: 29 és 31 perces nyitó-magas-alacsony-záró, továbbá 30 perces nyitó-magas-alacsony-záró adat 1 tick random zaj hozzáadásával és 30 perces nyitó-magas-alacsony-záró adat 2 tick random zaj hozzáadásával történik.

D. Indikátorok és azok paraméterei: A rendszerépítéshez a GSB szoftvert használjuk, mely 85 indikátort tartalmaz, ezeket az 1. táblázatban kategóriákba rendezve sorolom fel.

Az indikátorkészletből a rendszerek generálásához egyszerre 4 indikátort használunk fel. Az indikátorok paraméterei 0-100 tartományban 0,5 egységgel mozoghatnak.

### 1. Táblázat: Rendszerépítés indikátorai

*Forrás: Genetic System Builder, saját szerkesztés*

Trendkövető	Átlagos visszaállási	Momentum	Forgalom alapú	Volatilitás alapú	Szint alapú
AccumDistClose	Bollinger Lower Band	AccumDistMomentum	OBV	ADXR	Close
AccumDistCloseUpDn	Bollinger Upper Band	AccumDistMomentumClose	VWAP	ATR	CloseLessLowestLow
AccumDistDR	CCI	ADX		Chaikin Oscillator	CloseLessOpenDBpv
AccumDistDR0	DeCycler	FastK		Chaikin Oscillator Difference	CloseLessPrevCloseD
AccumSwingIndex	DeCycler Oscillator	MACD difference		Chaikin Volatility	CloseLessPrevCloseDBpv
Adaptive Moving Average	Hurst	Momentum		Keltner Lower Band	CloseLessPrevHighD
AveMedian	Median Band	MyRSI		Keltner Upper Band	CloseLessPrevLowD
Average Fc	Median Osc	Rate of change		Range	CloseLessPrevR3
Counter Trend	Roofing Filter1Pole	RSI		Standard deviation	CloseOverLowestLow
Counter Trend Median	RoofingFilter1 Pole2	SlowK		True Range	CloseOverPrevCloseD
CounterTrend2	ZeroCrossings	Stochastic			CloseOverPrevHighD
Dmi		SuperSmoother			CloseOverPrevLowD
Dmi Minus					CloseToHighLow5V4Pos
Dmi Plus					CloseToHighLow6V3Neg
Forward Reverse EMA					CloseToHighLow9
HighestFc					CloseToHighLow9V2Neg
LowestFc					CloseToPrevHighestHighLowestLow
TrendBiasExp					HighLow9LessClose
XAverage					HighLowC
					HighLowLvl
					HighLowLvlNeg
					LessCloseS2R2

					R1
					R2
					R3
					S1
					S1R1
					S2
					S2R2
					S3
					S3R3

E. Döntési feltétel vételi pozícióhoz: A GSB szoftverben az alábbi döntési feltételt határoztam meg vételi és eladási pozíciók nyitásához:

$$\begin{aligned}
& [\text{Előjel}(\text{indikátor1}(\text{paraméter1})) * \text{Hatvány}(\text{Abszolút} \\
& \text{érték}(\text{indikátor1}(\text{paraméter1})),0)] * [\text{Előjel}(\text{indikátor2}(\text{paraméter2})) * \\
& \text{Hatvány}(\text{Abszolút érték}(\text{indikátor2}(\text{paraméter2})),0)] * \\
& [\text{Előjel}(\text{indikátor3}(\text{paraméter3})) * \text{Hatvány}(\text{Abszolút} \\
& \text{érték}(\text{indikátor3}(\text{paraméter3})),0)] \text{ Felfelé keresztez } 0 \ \& \\
& (\text{indikátor4}(\text{paraméter4})) > X
\end{aligned}$$

A döntési feltétel első része az indikátorok értékének előjelenek meghatározásából áll, mely negatív vagy pozitív lehet. Mivel a hatványozásnál mindig a nulladik hatványra emelünk ezért a hatványozás eredménye 1. A hatvány változtatásával súlyozni lehet az indikátorokat. Ugyanakkor én ettől eltekintek, így a rendszereknél minden indikátort azonos súllyal veszünk számításba. A „Felfelé keresztez” formula pedig annyit tesz, hogy feltétel akkor igaz, ha az eredmény előző intervallumra számítva negatív volt, a jelenlegi intervallumon pedig pozitív.

A logikai formula második része pedig akkor igaz, ha az indikátor értéke egy bizonyos érték felett van.

Az eladási pozíció döntési feltétele a vételi inverze.

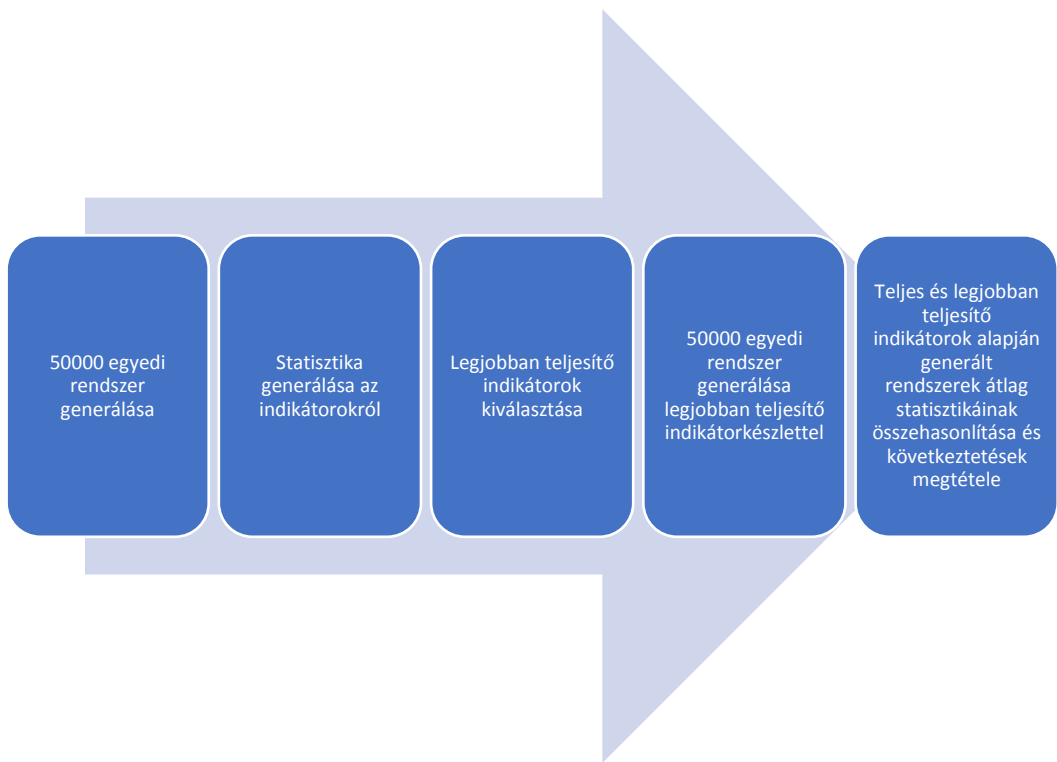
A döntési feltételhez tartozik a kereskedési mennyiség meghatározása, mely minden ügylet esetén 1 kontraktust jelent. Továbbá, meghatározunk egy vis major

kilépési feltételt: Az ügyletet lezárjuk, amennyiben nyitott vesztesége bármikor meghaladja a 2000 dollárt.

F. Fitnessz kritériumok: Minimum kritériumoknak a profit faktort és a Pearson korrelációt használjuk. A teszt időszakban a rendszerektől minimálisan 1,5 profit faktort és 0,9 korrelációt várunk el. Csak azokat a rendszereket mentjük el további vizsgálatra, melyek ezen teljesítménykritériumokat teljesítik.

G. Optimális indikátorkészlet meghatározása: Feltételezésem, hogy egy adott piacon bizonyos indikátorok jobb eredményű rendszereket generálnak, mint a többi indikátor. Az 2. ábra alapján első lépésként generálunk 50000 egyedi rendszert, melyben az összes indikátorunkat (1. táblázat) szerepeltetjük.

Ezután összesítjük az eredményeket. Feltételezzük azt, hogy ha egy indikátor többször fordul elő a jó teljesítményt nyújtó rendszerekben, mint a gyengébb teljesítményű rendszerekben, akkor az adott indikátor használatával jobb rendszereket lehet építeni. A gyakorlatban ezt úgy valósítjuk meg, hogy fitnessz kritérium alapján sorba rendezzük, majd a felénél két csoportra (Felső 50%, Alsó 50%) bontjuk a rendszereket. Ezután megvizsgáljuk, hogy egy indikátor hányszor fordult elő a Felső 50%, illetve az Alsó 50% csoportban. A két gyakoriságból kiszámítjuk az előfordulási arányt. Feltételezzük, hogy jobban teljesít az az indikátor, mely többször fordul elő jobban teljesítő rendszerekben, tehát melynek előfordulási aránya 0,5 fölött van.



2. ábra: Optimális indikátorkészlet meghatározása

*Forrás: Saját szerkesztés*

H. Rendszerek kiválasztása: Az optimális indikátorkészlet alapján generált 50000 rendszerből 8 rendszert fogunk kiválasztani:

- 2 rendszert a legmagasabb Pearson korreláció szerint
- 2 rendszert legmagasabb nettó profit alapján
- 2 rendszert legmagasabb profit faktor alapján
- 2 rendszert legnagyobb fitnessz kritérium alapján

A módszer egyszerű, de a különböző kritériumok alapján történő kiválasztással nagyobb lesz annak a valószínűsége, hogy a legjobb rendszerek egymáshoz képest különbözőek legyenek.

I. A kiválasztott 8 rendszert verifikáljuk a C. pontban meghatározott 4 adatfolyamon: A verifikációs ráta minimum 50% kell, hogy legyen. Egy

adatfolyamon egy rendszert akkor minősítünk verifikáltnak, ha legalább 1,2 profit faktor és 0,9 Pearson együtthatóval rendelkezik. Az 50%-os verifikációs rátából pedig az következik, hogy egy rendszert akkor tekintünk verifikáltnak, ha legalább két adatfolyamon a profit faktor és a Pearson korreláció meghaladta a minimumot.

J. A verifikált rendszerek walk-forward elemzése: Rögzített walk-forward elemzést végzünk azokra a rendszerekre, melyek verifikációs rátája legalább 50%. A rögzített walk-forward elemzés hatékonysági rátának legalább 50%-ot kell elérnie. Hatékonysági ráta alatt a mintán kívüli és a mintán belüli hozam arányát értjük.

K. Folyamat ismétlése következő piacra

L. Portfólió validálása: A portfólió sikeresen verifikált és 50%-nál magasabb WF hatékonysággal rendelkező rendszerekből épül fel. A portfólió validálása a C. pontban meghatározott validálási adathalmaz felhasználásával történik, melynek során meghatározzuk a validálási időszak Pearson korrelációs együtthatóját, illetve a nettó profitot.

## **2.2. A tradicionális befektetési modell módszertana**

A tradicionális befektetési modellben az adott eszközt megvásároljuk és meghatározott ideig a portfólióban tartjuk (Thomsett, 1998). A vételt megelőzheti az eszköz vagy annak árfolyamának különböző módszertan alapján történő elemzése.

A 2.1. fejezet A. pontjában ismertetett piacokat (sovány sertés, búza, kávé, fagyasztott narancslé) használom fel a tradicionális befektetési modell esetében is. A két modell összehasonlításának csak a validációs időszakban (2022.01.01. – 2023.09.01.) van értelme, hiszen a tréning és a teszt időszakokban a gépi modell generálása történik.



A tradicionális modell módszertana alapján 2022.01.01.-én mind a négy eszközosztályban a gépi modellel analóg módon annyi kontaktus kerül megvásárlásra, ahány rendszer a gépi modellben is van. A határidős kontraktus mindig a legközelebbi hónap szerződését jelenti. Amikor a piac az aktuális lejáratú hónapról áttér a következő lejáratú időszakra a szerződésünket átgörgetjük.

Az időszak végén – 2023.09.01. – a pozíciókat likvidáljuk és elkészítjük az időszakra vonatkozó profit statisztikát. A fő mutatószámunk a teljes időszakra vonatkozó nettó profit, mely mind a gépi modellépítésnél, mind pedig a tradicionális modellnél meghatározó lesz. A gépi modellépítésnél szintén meghatározó profit görbe korrelációja és a visszahúzás a tradicionális modell egy belépési és egy kilépési pontja miatt nem lesz használható összehasonlításra.

### **2.3. Egyszerű stratégia modell**

A gépi modellépítéssel szintén össze fogok hasonlítani egy egyszerű, de technikai elemzők által széles körben ismert kereskedési stratégiát. A mozgóátlag keresztezés során minden 30 perces időintervallumra kiszámítjuk az 50 és 200 mozgóátlagokat. Amennyiben a 50 mozgóátlag alulról keresztezi a 200 mozgóátlagot, akkor vételi pozíciót nyitunk és/vagy eladási pozíciót zárunk, ha az 50 mozgóátlag felülről keresztezi a 200 mozgóátlagot, akkor eladási pozíciót nyitunk és/vagy vételi pozíciót zárunk.

A stratégia kódját EasyLanguage programozási nyelven írtam meg, a szimulációhoz TradeStation kereskedési platformot használom.

A stratégia programkódja:

$$\text{FastAvg} = \text{AverageFC}(\text{Close}, 50);$$
$$\text{SlowAvg} = \text{AverageFC}(\text{Close}, 200);$$

if CurrentBar > 1 and FastAvg crosses over SlowAvg then

$$\text{Buy} ( ! ( \text{"MA2CrossLE"} ) ) \text{ next bar at market};$$

if CurrentBar > 1 and FastAvg crosses under SlowAvg then

Sell Short ( !( "MA2CrossSE" ) ) next bar at market;

A modellt a validációs időszakra futtatom le (2022.01.01. – 2023.09.01.) és a négy eszközosztályban a gépi modellel analóg módon annyi kontaktus kerül megvásárlásra, ahány rendszer a gépi modellben is van.

### 3. KUTATÁSI EREDMÉNYEK

Az ismertetett módszertan alapján határidős szerződéseken rendszereket építtek és verifikáltak Genetic System Builder (GSB), TradeStation és Portfolio Analyst Pro szoftverek segítségével. Az eredményekből összeállított portfóliót pedig a rendszerépítést megelőzően elrejtett adaton fogom tesztelni. Továbbá meghatározom ugyanezen portfólió tradicionális modell – megvesz és tart –, és egy egyszerű stratégia – mozgóátlag keresztezés - szerinti eredményeit.

#### 3.1. A gépi modell eredményei

Kutatásom során négy határidős piacot vizsgáltam meg. Gépi modellépítés során első lépésként 50000 rendszert építettem, elemeztem és rendszereztem a felhasznált indikátorokat, illetve kiszámoltam az átlagos mérőszámokat. Majd újabb 50000 rendszert építettem a jobban teljesítő indikátorok felhasználásával, mely után szintén kiszámoltam az átlagos mérőszámokat. Mind a négy határidős piac esetében azt találtam, hogy a jobban teljesítő indikátorok felhasználásával generált rendszerek magasabb átlagos mérőszámokat produkálnak.

A végleges portfólió összesen 20 rendszerből áll (2. táblázat), ezek közül:

- 8 sovány sertés (LH)
- 1 búza (W)
- 5 kávé (KC)
- 6 fagyasztott narancslé (OJ)

2. táblázat: Sikeresen verifikált és tesztelt rendszerek

*Forrás: saját szerkesztés*

Azonosító	Rendszer
LH.20230909-151352-585540-7cTi4	((Sign(GSB_FastK(14) of Data1) * Power(Absvalue(GSB_FastK(14) of Data1), 0)) * (Sign(GSB_HighLow9LessClose(22) of Data1) * Power(Absvalue(GSB_HighLow9LessClose(22) of Data1), 0)) *

	(Sign(GSB_HighLow9LessClose(30) of Data1) * Power(Absvalue(GSB_HighLow9LessClose(30) of Data1), 1.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 0
LH.20230909- 153133- 651956- hFY41	((Sign(GSB_FastK(24) of Data1) * Power(Absvalue(GSB_FastK(24) of Data1), 0)) * (Sign(GSB_CCI(46) of Data1) * Power(Absvalue(GSB_CCI(46) of Data1), 0)) * (Sign(GSB_CloseToHighLow5v4Pos(29) of Data1) * Power(Absvalue(GSB_CloseToHighLow5v4Pos(29) of Data1), 1.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 32.5
LH.20230909- 154219- 614805-Z8t7l	((Sign(GSB_CloseToHighLow5v4Pos(31) of Data1) * Power(Absvalue(GSB_CloseToHighLow5v4Pos(31) of Data1), 0)) * ((Sign(GSB_CCI(53) of Data1) * Power(Absvalue(GSB_CCI(53) of Data1), 0)) * (Sign(GSB_TrendBiasExp(24) of Data1) * Power(Absvalue(GSB_TrendBiasExp(24) of Data1), 1.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 15
LH.20230909- 154304- 998445- BVp3v	((Sign(GSB_CloseToHighLow5v4Pos(31) of Data1) * Power(Absvalue(GSB_CloseToHighLow5v4Pos(31) of Data1), 0)) * ((Sign(GSB_CCI(53) of Data1) * Power(Absvalue(GSB_CCI(53) of Data1), 0)) * (Sign(GSB_TrendBiasExp(24) of Data1) * Power(Absvalue(GSB_TrendBiasExp(24) of Data1), 1.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 45
LH.20230909- 154651- 313421-Uctor	((Sign(GSB_FastK(25) of Data1) * Power(Absvalue(GSB_FastK(25) of Data1), 0)) * (Sign(GSB_HighLow9LessClose(21) of Data1) * Power(Absvalue(GSB_HighLow9LessClose(21) of Data1), 0)) * (Sign(GSB_CloseOverPrevLowD of Data1) * Power(Absvalue(GSB_CloseOverPrevLowD of Data1), 1.25)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 50
LH.20230909- 154717-	((Sign(GSB_FastK(25) of Data1) * Power(Absvalue(GSB_FastK(25) of Data1), 0)) * (Sign(GSB_HighLow9LessClose(21) of Data1) *

342029-5YbCi	Power(Absvalue(GSB_HighLow9LessClose(21) of Data1), 0)) * (Sign(GSB_CloseOverPrevLowD of Data1) * Power(Absvalue(GSB_CloseOverPrevLowD of Data1), 1.25)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 42.5
LH.20230909-163551-960930-aGEIh	((Sign(DMI(25) of Data1) * Power(Absvalue(DMI(25) of Data1), 0)) * ((Sign(GSB_HighLowLvlNeg(28) of Data1) * Power(Absvalue(GSB_HighLowLvlNeg(28) of Data1), 0)) * (Sign(GSB_SlowK(11) of Data1) * Power(Absvalue(GSB_SlowK(11) of Data1), 1.25)))))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 10
LH.20230909-163602-983301-NzJxo	((Sign(DMIPlus(22) of Data1) * Power(Absvalue(DMIPlus(22) of Data1), 0)) * ((Sign(GSB_LessCloseS2R2v2 of Data1) * Power(Absvalue(GSB_LessCloseS2R2v2 of Data1), 0)) * (Sign(AdaptiveMovAvg(Close, 10, 4, 20) of Data1) * Power(Absvalue(AdaptiveMovAvg(Close, 10, 4, 20) of Data1), 1.75)))))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 20
W.20230917-045839-115959-MAQJ4	((Sign(GSB_CloseToHighLow5v4Pos(35) of Data1) * Power(Absvalue(GSB_CloseToHighLow5v4Pos(35) of Data1), 0)) * ((Sign(GSB_CloseToHighLow9v3(124) of Data1) * Power(Absvalue(GSB_CloseToHighLow9v3(124) of Data1), 0)) * (Sign(GSB_KeltnerChannelv2(Close, 105, 2) of Data1) * Power(Absvalue(GSB_KeltnerChannelv2(Close, 105, 2) of Data1), 2)))))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 22.5
KC.20230919-224241-493439-KFE1M	((Sign(GSB_SS_RSI(26) of Data1) * Power(Absvalue(GSB_SS_RSI(26) of Data1), 0)) * ((Sign(GSB_Highest(High, 106) of Data1) * Power(Absvalue(GSB_Highest(High, 106) of Data1), 0)) * (Sign(GSB_AccumDistMomv2(Ticks) of Data1) * Power(Absvalue(GSB_AccumDistMomv2(Ticks) of Data1), 0.75)))))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 55
KC.20230919-200905-422000-BuuXP	((Sign(StandardDev(Close, 4, 1) of Data1) * Power(Absvalue(StandardDev(Close, 4, 1) of Data1), 0)) * ((Sign(GSB_KeltnerChannelv2(Close, 18, 3.5) of Data1) * Power(Absvalue(GSB_KeltnerChannelv2(Close, 18, 3.5) of Data1), 0)) * (Sign(GSB_CounterTrendMedian(Close, 12, 2.5)

	of Data1) * Power(Absvalue(GSB_CounterTrendMedian(Close, 12, 2.5) of Data1), 0.5)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 0
KC.20230919-153229-046788-ZTBD5	((Sign(GSB_ChaikinVolatilityv2(3, 3) of Data1) * Power(Absvalue(GSB_ChaikinVolatilityv2(3, 3) of Data1), 0)) * ((Sign(StandardDev(Close, 8, 3) of Data1) * Power(Absvalue(StandardDev(Close, 8, 3) of Data1), 0)) * (Sign(GSB_AvgTrueRange(28) of Data1) * Power(Absvalue(GSB_AvgTrueRange(28) of Data1), 1.5)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 25
KC.20230919-233504-836152-eyBkv	((Sign(GSB_CounterTrend(Close, 150, 1) of Data1) * Power(Absvalue(GSB_CounterTrend(Close, 150, 1) of Data1), 0)) * ((Sign(GSB_AveLessMedianv2(Close, 114, 5) of Data1) * Power(Absvalue(GSB_AveLessMedianv2(Close, 114, 5) of Data1), 0)) * (Sign(GSB_Highest(High, 30) of Data1) * Power(Absvalue(GSB_Highest(High, 30) of Data1), 0.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 30
KC.20230919-210702-646795-NtQek	((Sign(GSB_SS_RSI(32) of Data1) * Power(Absvalue(GSB_SS_RSI(32) of Data1), 0)) * ((Sign(GSB_SS_RSI(7) of Data1) * Power(Absvalue(GSB_SS_RSI(7) of Data1), 0)) * (Sign(GSB_CounterTrend(Close, 199, 4) of Data1) * Power(Absvalue(GSB_CounterTrend(Close, 199, 4) of Data1), 1.5)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 67.5
OJ.20230922-045352-796815-KIvBH	((Sign(GSB_ChaikinVolatilityv2(13, 140) of Data1) * Power(Absvalue(GSB_ChaikinVolatilityv2(13, 140) of Data1), 0)) * ((Sign(GSB_CCI(4) of Data1) * Power(Absvalue(GSB_CCI(4) of Data1), 0)) * (Sign(GSB_CloseLessPrevLowDv2 of Data1) * Power(Absvalue(GSB_CloseLessPrevLowDv2 of Data1), 0)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 7.5
OJ.20230922-065359-186625-D0RI0	((Sign(GSB_CloseLessPrevHighDv2 of Data1) * Power(Absvalue(GSB_CloseLessPrevHighDv2 of Data1), 0)) * ((Sign(GSB_CCI(17) of Data1) * Power(Absvalue(GSB_CCI(17) of Data1), 0)) *

	<p>(Sign(GSB_HighLow9LessClose(11) of Data1) * Power(Absvalue(GSB_HighLow9LessClose(11) of Data1), 0)))) Cross 0 &amp; 0 &amp; GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 &gt; 60</p>
OJ.20230922-064325-146027-RBWAc	<p>((Sign(GSB_DeCyclerOscillator(35, 45) of Data1) * Power(Absvalue(GSB_DeCyclerOscillator(35, 45) of Data1), 0)) * ((Sign(GSB_HighLow9LessClose(36) of Data1) * Power(Absvalue(GSB_HighLow9LessClose(36) of Data1), 0)) * (Sign(GSB_DMI(48) of Data1) * Power(Absvalue(GSB_DMI(48) of Data1), 0)))) Cross 0 &amp; 0 &amp; GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 &gt; 40</p>
OJ.20230922-064550-334839-fAonB	<p>((Sign(GSB_DeCyclerOscillator(35, 45) of Data1) * Power(Absvalue(GSB_DeCyclerOscillator(35, 45) of Data1), 0)) * ((Sign(GSB_HighLow9LessClose(36) of Data1) * Power(Absvalue(GSB_HighLow9LessClose(36) of Data1), 0)) * (Sign(GSB_DMI(79) of Data1) * Power(Absvalue(GSB_DMI(79) of Data1), 0)))) Cross 0 &amp; 0 &amp; GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 &gt; 40</p>
OJ.20230922-045427-522624-OtxU2	<p>((Sign(GSB_ChaikinVolatilityv2(13, 140) of Data1) * Power(Absvalue(GSB_ChaikinVolatilityv2(13, 140) of Data1), 0)) * ((Sign(GSB_CCI(4) of Data1) * Power(Absvalue(GSB_CCI(4) of Data1), 0)) * (Sign(GSB_CloseLessPrevLowDv2 of Data1) * Power(Absvalue(GSB_CloseLessPrevLowDv2 of Data1), 0)))) Cross 0 &amp; 0 &amp; GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 &gt; 20</p>
OJ.20230922-234520-464434-4x49z	<p>((Sign(GSB_MedianBand(Close, 43, 1) of Data1) * Power(Absvalue(GSB_MedianBand(Close, 43, 1) of Data1), 0)) * ((Sign(GSB_CloseOverPrevHighDv2 of Data1) * Power(Absvalue(GSB_CloseOverPrevHighDv2 of Data1), 0)) * (Sign(GSB_CloseLessPrevLowDv2 of Data1) * Power(Absvalue(GSB_CloseLessPrevLowDv2 of Data1), 0)))) Cross 0 &amp; 0 &amp; GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 &gt; 25</p>

A validációs eljárás során igazoltam, hogy ezek a rendszerek a vizsgált időszakban (2022.01.01. – 2023.09.01.), - amely a rendszerek számára ezt megelőzően ismeretlen volt - megbízható, stabil eredményeket produkáltak.

A feladunk, hogy a validációs eredményeket összefűzzük, kiszámoljuk a portfólió szintű eredményeket, azokból levonjuk a megfelelő következtetéseket.

### 3. táblázat: A portfólió összesített eredményei

*Forrás: Portfolio Analyst Pro, saját szerkesztés*


<b>Tréning és Teszt időszak</b>		<b>Validációs időszak</b>	
Nettó profit (\$)	Pearson mutató	Nettó profit (\$)	Pearson mutató
2891390	0,997	290667	0,967

A 3. táblázatból látható, hogy a validációs időszakban, amely a rendszerek számára teljesen ismeretlen, ugyanakkor valós piaci adatokat tartalmazott, a nettó profit arányosan alakul a tréning és teszt időszakban számított értékekkel. Tehát ez bizonyítja azt, hogy képesek vagyunk gépi modellépítés módszerrel olyan algoritmikus kereskedési rendszereket építeni, melyek élő kereskedés során megállják a helyüket, az eredmények jövőbeli piaci árfolyam adatokon nyereséget mutatnak. Ebből a szempontból nincs jelentősége annak, hogy a validációs időszakban nem egy tényleges kereskedési számlán kereskedtünk. Természetesen a kereskedési ellenségek, melyek csak élő kereskedés során jelentkeznek, mint a technológiai hibák, emberi interakciók, az elcsúszás természetesen befolyásolták volna az eredményeket. Ugyanakkor a validáció során figyelembe vettünk az adott piacra jellemző átlagos elcsúszást és kereskedési jutalékot. Ezek biztosítják azt, hogy validációs eljárás eredményei megközelítették volna a tényleges élő kereskedés során elért nettó profitot.

A 3. ábra, melyen az összesített profit görbe látható majdnem egy 45 fokos egyenes. A validációs időszakban a görbe karakterisztikája, meredeksége nagyon hasonló a tréning és teszt időszakokéhoz, tehát bizonyítást nyert az, hogy



lehetséges olyan portfóliót építeni, mely kiegyensúlyozott nyereséget és a profit görbe folytatását eredményezi a rendszer számára ismeretlen árfolyam adatokon.



3. ábra: A portfólió összesített profit görbéje

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

### 3.2. A tradicionális modell és eredményei

A gépi modell portfólió összesen 20 rendszerből áll (8 LH, 1 W, 5 KC, 6 OJ). Megtartva a konzisztenciát és az összehasonlíthatósági követelményeket a tradicionális - vesz és tart - portfólióba a validációs időszak kezdetén minden piacról annyi kontaktus kerül megvásárlásra, ahány rendszer a gépi modellben is van – tekintettel arra, hogy minden rendszer egy szerződéssel kereskedik. 2022.01.01.-én nyitjuk majd 2023.09.01. zárjuk az összes ügyletet. A tranzakciós költség elhanyagolható, mivel piaconként csak egyetlen ügylet van. A validációs időszak eszközönkénti árfolyammozgását a 4. ábra mutatja.



4. ábra: Sovány sertés (LH), búza (W), kávé (KC), fagyasztott narancslé (OJ) árfolyamának alakulása a validációs időszakban

*Forrás: TradeStation Inc.*

A paramétereknek megfelelő tradicionális portfólió eredményeit pedig a 4. táblázat foglalja össze. Ebből kiolvasható, hogy a több mint másfél év alatt csak a fagyasztott narancslé piacon tudunk nyereséget realizálni, ezen a piacon ráadásul az árfolyam majdnem négyszeresére nőtt. Ennek köszönhető, hogy a fagyasztott narancslé piac nettó nyeresége ellensúlyozni tudta az többi piac veszteségét és a validációs időszakot 60160 \$ nyereséggel zártuk.

4. táblázat: A tradicionális modell eredményei

*Forrás: saját szerkesztés*

	Vétel időpontja	Vételi árfolyam (\$)	Kontraktus mérete	Mennyiség	Értéke (\$)	Eladás időpontja	Eladási árfolyam (\$)	Érték (\$)	Nettó hozam (\$)
<b>Sovány sertés (LH)</b>	2022-01-01	91,425	40000 font	8	292560	2023-09-01	85,725	274320	-18240
<b>Búza (W)</b>	2022-01-01	946,25	5000 véka	1	47312,5	2023-09-01	628,75	31437,5	-15875
<b>Kávé (KC)</b>	2022-01-01	202,90	37500 font	5	380437,5	2023-09-01	145,90	273562,5	-106875
<b>Fagyasztott narancslé (OJ)</b>	2022-01-01	82,60	15000 font	6	74340	2023-09-01	306,10	275490	201150
<b>Összesen</b>									60160

### 3.3. Egyszerű kereskedési modell eredményei

A 2.3 fejezetben ismertetett mozgóátlag keresztezés stratégiát EasyLanguage és TradeStation kereskedési platform segítségével futtatom le. Piaconként a kereskedési mennyiségek igazodnak gépi modellhez: Összesen 20 kontraktussal kereskedünk (8 LH, 1 W, 5 KC, 6 OJ). A tranzakciós költségek megegyeznek a gépi modellépítésnél ismertetett összegekkel.


Az 5. táblázat az egyszerű modell által elért eredményeket mutatja. Látható, hogy a stratégia nem tudott profitot termelni a validációs időszakban.

5. táblázat: Egyszerű kereskedési stratégia eredményei a validációs időszakban

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

	Kontraktusok száma	Bruttó profit (\$)	Tranzakciós költség (\$)	Nettó profit (\$)	Ügyletek száma	Profit faktor
<b>Sovány sertés (LH)</b>	8	-112968	6032	-119000	29	0.57
<b>Búza (W)</b>	1	9801	2759	7042	89	1.11
<b>Kávé (KC)</b>	5	58156	10875	47281	50	1.16
<b>Fagyasztott narancslé (OJ)</b>	6	-60069	3996	-64065	37	0.71
<b>Összesen</b>	20	-105080	23662	-128742	205	0.85

A 5. ábra értelmezése után nyilvánvaló, hogy a profitgörbe hektikus, kezdeti felívelő szakasz után a stratégia folyamatosan veszteséget termel.



5. ábra: Az egyszerű modell profit görbéje a vizsgált időszakban

*Forrás: Portfolio Analyst Pro*

## 4. KÖVETKEZTETÉSEK, JAVASLATOK

Igazolást nyert, hogy a gépi modellépítés sikeres megközelítése a tőzsdei kereskedésnek, melyben a mesterséges intelligencia használata megkerülhetetlen. A fejlett keresési algoritmusok, illetve a gépi tanulás lehetőséget biztosít arra, hogy nagy számú kombinációból kiválasszuk azokat az algoritmusokat, melyek nyereségesek voltak a vizsgált időszakokban. A verifikációs eljárások segítségével pedig növelni tudjuk annak valószínűségét, hogy a kiválasztott rendszerek jövőbeli adatokon is sikeresen kereskedjenek. Az eredményekből nyilvánvalóvá vált, hogy ezek a gépi modellek stabilabb és magasabb hozamot képesek elérni, mint a tradicionális modell – megvesz és tart – és az egyszerű stratégia szerinti kereskedés.

Természetesen a siker kulcsa a módszertan pontos követésében, az ügyletek szisztematikus végrehajtásában és abban rejlik, hogy bizonyos fokú bizalmat előlegezzünk meg a kereskedési modelleknek, hiszen azt lehetetlen megmondani, hogy egy-egy rendszer mennyi ideig fog a jövőben működni, és az elvárt profitot generálni. A verifikációs és validációs eljárásoknak ebben van nagy jelentősége, hiszen segítségével modellezni tudjuk az árfolyam karakterisztikájában és belső életében történt változásokat és ki tudjuk számítani, hogy a rendszereink hogyan reagálnak azokra. A robusztus rendszerek nagyobb bizalmat sugároznak a kereskedők felé, hiszen több helyzetben is stabil eredményeket produkálnak. Ugyanakkor elképzelhető olyan eset is, amelyben már az éles kereskedés első napjától veszteséget generál egy stratégia, így mindenképpen szükséges egy olyan módszertan kidolgozása, mely objektív mérőszámok alapján hoz döntést arról, hogy adott rendszer meddig maradhat a portfólió része, hol van az a pont, ami után azt törölnünk kell és egy másik rendszerrel helyettesíteni. Kutatásomnak ez nem volt célja, a fókusz a gépi modellépítés sokszínűségén volt, illetve azon, hogy építhető olyan portfólió, mely akár hosszabb távon is, emberi beavatkozás nélkül képes nyereséget termelni és képes legyőzni a tradicionális befektetési modellt. A diverzifikációt használtam fel arra, hogy egy-egy rendszer teljesítménye csak a

saját súlyával terhelje az összeteljesítményt, így tulajdonképpen nem volt lényeges, amikor egy-egy rendszer nem hozta az elvárt eredményeket. Úgy gondolom, hogy a teljes folyamat reprodukálható, vagyis, ha megismételném a gépi modellépítést, akkor az eredmények hasonlóak lennének.

Lényeges volt annak kiszámítása, hogy a generált rendszerek egymással milyen kapcsolatban állnak. Többször találkoztunk azzal, hogy néhány rendszer erős korrelációban áll egymással. Ezt a jelenséget közelebbről megvizsgálva azt tapasztaltuk, hogy ezen rendszerek felépítése nagyon hasonló, indikátorkészletük nagy százalékban megegyezik, azok főként paramétereikben térnek el egymástól. Célszerű ezen rendszerek kiszűrése, hiszen mint azt az előzőekben is említettem nem tudhatjuk, hogy egy rendszer ismeretlen árfolyam adatokon hogyan fog viselkedni, így célszerű a portfólióban olyan rendszereket szerepeltetni, melyek között maximum enyhe korreláció áll fenn – vagyis indikátor- és paraméterkészletük különböző.

A gépi modellépítés szakirodalomban részletezett módszertan felhasználásával sikeresen építettem meg egy portfóliót, melyet ugyan élő kereskedésben nem, de számára ismeretlen adatokon futtattam. Bár ez a teszt sikeres volt, azt nem szabad elfelejteni, hogy az élő kereskedés során több előre nem látható befolyásoló tényező nehezíti a végrehajtást, mint az elcsúszás, vagyis a kívánt és a tényleges árfolyam közötti különbség. Az élő kereskedés során ismerni kell és főleg el kell fogadni a lehetséges kockázatokat. Még ennél is fontosabb elfogadni azokat kockázatokat, melyek a portfólió sikertelenségéből adódnak és valós anyagi veszteséggel járnak.

## 5. ÚJ ÉS ÚJSZERŰ TUDOMÁNYOS EREDMÉNYEK

Kutatásom során genetikus algoritmusokkal építettem tőzsdei kereskedési rendszereket. Ezeket összehasonlítottam a tradicionális – megvesz és tart – befektetési modellel, továbbá egy egyszerű és általánosan ismert stratégiával – mozgóátlag keresztezés. Megállapítottam, hogy a gépi modellépítés képes jobb eredményeket és magasabb nettó profitot produkálni.

A rendszerépítés fő lépései folyamatai előre definiáltak és számos irodalomban fellelhetőek, ugyanakkor az a folyamat mellyel a rendszereket építettem egyedi, általam definiált lépéseket és paramétereket is tartalmaz. Eredménynek tekintem a rendszerépítés általam definiált folyamatát (3.1. fejezet), hiszen ezzel a módszertannal sikeresen építettem olyan kereskedési rendszereket, melyek hosszabb távon is hozták az elvárt eredményeket, illetve a validációs időszakban a profit görbe Pearson korrelációja csak kismértékben tért el tréning és teszt időszakok profit görbéjének korrelációjától.

Igazolást nyert, hogy a technikai elemzés indikátorai és azok paramétereit között vannak olyanok, melyekkel valid kereskedési rendszereket lehet létrehozni, és melyek megállják a helyüket élő kereskedés során is. A technológia lehetőséget biztosít arra, hogy fejlett keresési algoritmusok és a mesterséges intelligencia használatával lényegesen hatékonyabban és nem utolsó sorban gyorsabban találjuk meg ezeket az indikátorokat és azok paramétereit.

Megállapítottam, hogy a pénzügyi piacokon léteznek olyan számítógép vezérelt algoritmikus modellek, melyek hosszú távon képesek nyereséget termelni. A határidős piacokon épített portfólió a vizsgált időszakban, megbízható, stabil profitot produkált. A folyamat megismételhető, illetve az eredmények reprodukálhatóak.

Meghatároztam, hogy a különböző indikátorokon alapuló diverzifikált rendszerek összesített, mintán kívüli kereskedési eredménye kiegyensúlyozottabb, mint egy-egy rendszer egyéni eredménye. Az egyes rendszerek profit görbéjének korrelációja alacsonyabb volt, mint a teljes portfólióé függetlenül attól, hogy

melyik időszakban vizsgáltuk azt. Így igazolást nyert a diverzifikáció szükségessége, illetve az, hogy a diverzifikáció a kockázatmenedzsment egyik legegyszerűbb ugyanakkor legfontosabb eszköze.

Megállapítottam továbbá, hogy a különböző technikai indikátorok különböző hatékonysággal használhatók a különböző piacokon. Az általam vizsgált határidős piacok esetében azt találtam, hogy adott piacon a jobb eredményeket mutató indikátorok segítségével nyereségesebb kereskedési algoritmusokat tudunk generálni.



## **6. A SZERZŐNEK AZ ÉRTEKEZÉS TÉMAKÖRÉHEZ KAPCSOLÓDÓ PUBLIKÁCIÓI**

1. Csesznik, Zoltán (2021). Az algoritmikus kereskedés anatómiája  
CONTROLLER INFO 9 : 4 pp. 40-43. Paper:  
10.24387/CI.2021.különszám.7 , 4 p.  
Közlemény:32494880 Nyilvános Forrás Idéző Folyóiratcikk (Szakcikk )
2. Csesznik, Zoltán (2023). Creating trading algorithms using machine  
model building methods  
CONTROLLER INFO 11 : Special Issue pp. 57-61. Paper:  
10.24387/CI.2023.SPECIAL ISSUE.9 , 5 p.  
Közlemény:34525433 Nyilvános Forrás Folyóiratcikk (Szakcikk )
3. Csesznik, Zoltán (2023). Határidős piacok és szerződések működési  
mechanizmusai  
CONTROLLER INFO 11 : 3 pp. 39-42. Paper: 10.24387/CI.2023.3.8 , 4  
p.  
Közlemény:34525377 Nyilvános Forrás Folyóiratcikk (Szakcikk )
4. Csesznik, Zoltán (2021). Irányítatlan árfolyamkereskedés – stabil profit a  
pénzügyi piacokon  
CONTROLLER INFO 9 : 4 pp. 44-48. Paper: 10.24387/CI.2021.4.8 , 5  
p.  
Közlemény:32538622 Nyilvános Forrás Folyóiratcikk (Szakcikk )
5. Csesznik, Zoltán (2022). A kereskedési algoritmusok ellenségei  
CONTROLLER INFO 10 : 4 pp. 52-56. , 5 p.  
Közlemény:34525295 Nyilvános Forrás Idéző Folyóiratcikk (Szakcikk )

6. Zoltán, Csesznik ; Sándor, Gáspár ; Gergő, Thalmeiner ; Zoltán, Zéman (2021). Examining the effectiveness of fundamental analysis in a long-term stock portfolio  
ECONOMIC ANNALS-XXI 190 : 5-6(2) pp. 119-127. , 9 p.  
Közlemény:32556708 Admin láttamozott Forrás Idéző Folyóiratcikk (Szakcikk )
7. Gáspár, Sándor ; Thalmeiner, Gergő ; Csesznik, Zoltán ; Zéman, Zoltán (2022). Részvényár előrejelzés neuro-fuzzy modell alkalmazásával, pénzügyi-számviteli mutatószámok felhasználásával  
Közlemény:33568016 Nyilvános Forrás Könyvrészlet (Absztrakt / Kivonat )
8. Csesznik, Zoltán (2022). Kripto a jövőbe csomagolva  
Pécs, Magyarország : Pécsi Tudományegyetem Állam- és Jogtudományi Kar (PTE ÁJK) pp. 40-48. , 9 p.  
Közlemény:33070335 Nyilvános Forrás Könyvrészlet (Konferenciaközlemény )
9. Zoltán, Csesznik (2022). Enemies of trading algorithms  
In: Zsolt, Pál (szerk.) New aspects of financial literacy : Collection of Studies  
Miskolc, Magyarország : FINTELLIGENCE Financial Literacy Center 186 p. pp. 26-38. , 13 p.  
Közlemény:33366588 Munkapéldány Nem nyilvános Forrás Könyvrészlet (Szaktanulmány )
10. Suhajda, Ádám ; Csesznik, Zoltán (2021). Tőzsdék és ECN kereskedési rendszerek versenyhelyezete az algoritmikus kereskedés piacán, valamint a BÉT stratégiájának revíziója a témában  
CONTROLLER INFO 9 : 4 pp. 53-58. , 6 p.

- Közlemény:32536606 Nyilvános Forrás Idéző Folyóiratcikk (Szakcikk )
11. Csesznik, Zoltán (2022). Beating The Indexes Using Fundamental Analysis In Long-Term Trading: Searching For Alpha By Using Company Fundamentals  
Technical Analysis of Stocks&Commodities 40 : 5 pp. 26-31. , 6 p.  
Közlemény:32788214 Nyilvános Forrás Folyóiratcikk (Szakcikk )
  12. Zoltan, Csesznik (2021). Fundamental risk management in trading stocks  
Aspects of Financial Literacy : Proceedings of the International Scientific and Practical Conference March 22-23, 2021  
Sumy, Ukrajna : Sumy State University (SSU) 417 p. pp. 389-402. , 14 p.  
Közlemény:32534330 Nyilvános Forrás Idéző Könyvrészlet (Konferenciaközlemény )
  13. Csesznik, Zoltán (2012). Matching strategy and stocks  
Active Trader 13 : 7 pp. 28-31. , 4 p.  
Közlemény:32290898 Nyilvános Forrás Folyóiratcikk (Szakcikk )
  14. Csesznik, Zoltán (2012). Defeating Slippage  
Technical Analysis of Stocks&Commodities 30 : 5 pp. 38-40. , 3 p.  
Közlemény:32290890 Nyilvános Forrás Folyóiratcikk (Szakcikk )
  15. Csesznik, Zoltán (2021). A vállalatértékelés fontossága a kereskedési döntések meghozatalának előkészítésében  
CONTROLLER INFO 9 : 2 pp. 59-62. , 4 p.  
Közlemény:32122168 Nyilvános Forrás Idéző Folyóiratcikk (Szakcikk )
  16. Csesznik, Zoltán (2021). Tőzsdei indikátorok hatékonysága  
CONTROLLER INFO 9 : 3 pp. 28-31. , 4 p.  
Közlemény:32290793 Nyilvános Forrás Folyóiratcikk (Szakcikk )

## 7. FELHASZNÁLT IRODALOM

1. Aslam, F., Mohti, W., Ali, H., & Ferreira, P. (2023). Interplay of multifractal dynamics between shadow policy rates and stock markets. *Heliyon*, 9(7), e18114. <https://doi.org/10.1016/j.heliyon.2023.e18114>
2. Chen, J.-H., & Tsai, Y.-C. (2020). Encoding candlesticks as images for pattern classification using convolutional neural networks. *Financial Innovation*, 6(1), 26. <https://doi.org/10.1186/s40854-020-00187-0>
3. Fry-McKibbin, R., & McKinnon, K. (2023). The evolution of commodity market financialization: Implications for portfolio diversification. *Journal of Commodity Markets*, 32, 100360. <https://doi.org/10.1016/j.jcomm.2023.100360>
4. Huang, S.-C., Chiou, C.-C., Chiang, J.-T., & Wu, C.-F. (2020). Online sequential pattern mining and association discovery by advanced artificial intelligence and machine learning techniques. *Soft Computing*, 24(11), 8021–8039. <https://doi.org/10.1007/s00500-019-04100-5>
5. Kühl, N., Schemmer, M., Goutier, M., & Satzger, G. (2022). Artificial intelligence and machine learning. *Electronic Markets*, 32(4), 2235–2244. <https://doi.org/10.1007/s12525-022-00598-0>
6. Nassar, D. S. (2006). *Ordinary people, extraordinary profits: How to make a living as an independent stock, options, and futures trader*. Wiley.
7. Nicholls, J. F., & Engelbrecht, A. P. (2019). Co-evolved genetic programs for stock market trading. *Intelligent Systems in Accounting, Finance and Management*, 26(3), 117–136. <https://doi.org/10.1002/isaf.1458>
8. Thomsett, M. C. (1998). *Mastering fundamental analysis*. Dearborn Financial Pub.