

# DOKTORI (PHD) ÉRTEKEZÉS

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. BEVEZETÉS.....	7
1.1. A téma jelentősége, aktualitása.....	7
1.2. Kutatási célok és hipotézisek.....	10
2. SZAKIRODALMI ÁTTEKINTÉS .....	12
2.1. A tőzsdei kereskedés értelmezése.....	12
2.1.1. Árfolyamok megjelenítése, értelmezése, komplex vizsgálata .....	12
2.1.2. Határidős szerződések.....	19
2.1.3. Fundamentális elemzés és az azon alapuló kereskedési módok .....	25
2.1.4. Technikai elemzés.....	27
2.1.5. Indikátorok bemutatása és csoportosítása .....	28
2.1.6. Diszkrecionális kereskedési módok .....	36
2.1.7. Algoritmikus kereskedés anatómiája .....	37
2.1.8. Az algoritmikus kereskedés ellenségei .....	39
2.1.9. Portfólió diverzifikáció .....	43
2.1.10. Kockázat- és profitmenedzsment .....	45
2.2. Gépi modellépítés .....	47
2.2.1. Az adatfolyam definiálása.....	48
2.2.2. Indikátorkosár, indikátorok és változók.....	49
2.2.3. Be- és kilépési feltételek .....	49
2.2.4. Tanulási, tesztelési, validálási periódusok .....	50
2.2.5. Genetikus algoritmusok használata, jelentősége.....	51
2.2.6. Fitness kritériumok .....	53
2.2.7. Eredmények tesztelése, validálása .....	54
2.3. A rendszerépítés eszközei.....	58
3. ANYAG ÉS MÓDSZERTAN.....	60
3.1. A kutatás során alkalmazott gépi rendszerépítési modell meghatározása .....	60

3.2. A tradicionális befektetési modell módszertana .....	65
3.3. Egyszerű stratégia modell.....	65
4. EREDMÉNYEK .....	67
4.1. Sovány sertés (LH) rendszerek.....	67
4.1.1. Optimális indikátorkészlet meghatározása.....	67
4.1.2. Rendszerek kiválasztása, tesztelése, és verifikálása .....	69
4.1.3. LH rendszerek validálása .....	72
4.2. Búza (W) határidős rendszerek.....	74
4.2.1. Optimális indikátorkészlet meghatározása.....	75
4.2.3. Rendszerek kiválasztása, tesztelése, verifikálása.....	76
4.2.3. Búza (W) rendszerek validálása.....	79
4.3. Kávé (KC) határidős rendszerek.....	82
4.3.1. Optimális indikátorkészlet meghatározása.....	82
4.3.2. Rendszerek kiválasztása, tesztelése, verifikálása.....	83
4.3.3. Kávé (KC) rendszerek validálása.....	86
4.4. Fagyasztott narancslé (OJ) határidős rendszerek.....	89
4.4.1. Optimális indikátorkészlet meghatározása.....	89
4.4.2. Rendszerek kiválasztása, tesztelése, verifikálása.....	90
4.4.3. Fagyasztott narancslé (OJ) rendszerek validálása.....	93
4.5. A gépi modellépítés portfólió szintű eredményei .....	96
4.6. A tradicionális modell eredményei .....	97
4.7. Egyszerű kereskedési modell eredményei .....	100
4.8. Kutatási hipotézisek igazolása .....	101
4.9. Új és újszerű tudományos eredmények .....	109
5. KÖVETKEZTETÉSEK, JAVASLATOK .....	111
6. ÖSSZEFOGLALÁS .....	113
7. SUMMARY .....	115
MELLÉKLETEK .....	116

M1: Irodalomjegyzék.....	116
M2: Ábrajegyzék .....	124
M3: Táblázatjegyzék .....	126

# 1. BEVEZETÉS

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 essenciája, 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. Az évek során többször is elbuktam – hasonlóan a körülöttem lévő munkatársak jelentős részéhez.

Jelen értekezésemben saját tapasztalataimat, kutatásaimat, eredményeimet is megosztom, remélve azt, hogy ezek hasznos információk fognak bizonyulni mások számára is.

## 1.1. A téma jelentősége, aktualitása

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 túláradó 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.

Aki pénzügyi eszközökkel szeretne kereskedni minden bizonnyal az első lépésnél valamilyen tudásbázist fog keresni, hogy mi alapján, hogyan kereskedjen és miként értelmezze az árfolyam változásait.

A legtöbb ember – sok-sok évvel ezelőtt jómagam is – elhiszi azt, hogy a tudás megszerzésével automatikusan sikeres kereskedővé válik. Amikor egy tudásbázis megismerése után annak alkalmazása során az eredmények elmaradnak a várakozásoktól, akkor keresnek egy újabbat, amely bizonyos ideig hittel tölti el őket. Ez a folyamat ismétlődik és nagyon hosszú ideig tart, a

végére belefáradnak abba, hogy képtelenek konzisztensen és hosszú távon profitot realizálni aktív tőzsdei kereskedéssel.

De egyáltalán létezik e hosszútávon nyereségesen működő aktív kereskedési modell? Az S&P500 tőzsdeindex az elmúlt 100 évben felfelé mozgott (1. ábra), így egy jól megtervezett és diverzifikált portfólió hosszú távon nagy valószínűséggel hozamot fog generálni.



1. ábra: S&P 500 tőzsdeindex inflációval módosítva

*Forrás: Macrotrends.net*

Véleményem szerint a sikeres kereskedés kulcsa nem a minél nagyobb tudásban rejlik, hiszen ebben az esetben a jövőbeli eseményeket kell stabilan előre jelezni. Meg kell találni az árfolyamban azokat a mintákat, melyek periodikusan ismétlődnek, és melyek kimenetele hasonló (J.-H. Chen & Tsai, 2020).

A másik kérdés, hogy lehetséges e számszerűsíteni és statisztikailag bizonyítani, hogy valaki valamilyen módszerrel hatékonyan meg tudja jósolni az árfolyam változásokat.

Azt gondolom, hogy természetünkéből adódóan mindenki jó valamiben. Adottságaink lehetővé teszik, hogy az élet egy-egy területén jobbak legyünk a többi embernél. Gondoljunk csak egy szobrászra vagy egy festőre. Néhányunk úgy születik, hogy adottsága van fantasztikus képeket festeni bármilyen előképzettség vagy tanulás nélkül. A legtöbb ember bármennyit gyakorolhat és tanulhat, soha nem fogja elérni azt a szintet, amit az a festő birtokol, aki ezzel az adottsággal született. Hasonló a helyzet a tőzsdei kereskedésnél is. Chan (2013) szerint az emberek kis



százaléka természetes adottságokkal rendelkezik arra, hogy hosszú távon nyereségesen vegyen és adjon el pénzügyi eszközöket. Mások tanulással és kitartással fejleszthetik képességeiket, és sok-sok év próbálkozás és még több pénzügyi veszteség után szintén sikeresek lehetnek.

Egy harmadik csoport – melynek nézeteivel saját magam is teljes mértékben egyetértek – a technológia szülte vívmányokat használja a célból, hogy számítógépes algoritmusok segítségével megalkossa a hosszú távon sikeres kereskedési modelleket (Liu és mtsai., 2023).

A hatékony piacok elmélete szerint a pénzügyi eszköz árfolyama minden pillanatban tartalmazza az összes elérhető információt, azokat mindig a valós értéken adják és veszik, az árfolyam véletlenszerűen alakul és így nem lehetséges előre jelezni az árfolyamok jövőbeli alakulását (Kissell, 2020). Az alul és felülértékelés fogalma nem létezik, ezért lehetetlen túlteljesíteni a teljes piac teljesítményét. Az elmélet szerint sem technikai, sem pedig fundamentális elemzéssel nem lehet konzisztensen extra haszonra szert tenni, az egyetlen út a bennfentes kereskedés, amely olyan információkra alapoz, amik csak a jövőben lesznek nyilvánosak (Chang és mtsai., 2022).

A tudományos világ rengeteg bizonyítékkal próbálja alátámasztani a hatékony piacok elméletét, ugyanakkor számos bizonyíték van az ellenkezőjére is. Például a világ leghíresebb befektetője Warren Buffett, hosszú évtizedek óta tartó pályája alatt éves átlagos nyeresége 10%-kal haladta meg a teljes piaci nyereséget. Nyilván 60 év elteltével ez nem lehet a véletlen műve (Schroeder, 2008).

De több más ismert és kevésbé ismert befektető is hasonló hozamokat képes realizálni. Úgy gondolom, hogy saját pénzügyi alapunk (Roidia Trading Funds Segregated Portfolio) három lezárt auditált éve jó úton halad afelé, hogy beírja a nevét az alfa hozamra képes pénzügyi alapok közé (1. táblázat).

1. táblázat: Roidia Trading Funds nettó havi hozamok (%)

*Forrás: Fund Advisers (Cayman) SPC obo ROIDIA Trading Fund Segregated Portfolio*

	Jan	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Annualized
2024	7.52	3.93											11.75
2023	0.25	-6.76	-2.38	0.65	7.19	2.68	0.10	-2.49	-1.58	-8.11	2.71	1.76	-6.72
2022	-2.81	-6.18	4.83	9.24	5.60	5.23	3.44	3.63	-14.29	4.36	3.82	8.50	25.30
2021	6.55	4.22	3.53	3.08	6.94	4.08	7.19	-5.24	0.91	-9.72	1.32	13.85	40.81
2020				15.55	-8.49	11.01	-0.09	1.66	7.41	16.48	-5.97	-0.27	39.89

## 1.2. Kutatási célok és hipotézisek

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.

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.

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 sikerebben 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. SZAKIRODALMI ÁTTEKINTÉS

### 2.1. A tőzsdei kereskedés értelmezése

#### 2.1.1. Árfolyamok megjelenítése, értelmezése, komplex vizsgálata

A tőzsdei kereskedés során a pénzügyi eszközökkel vételi-eladási ügyleteket kötnek. Ezek az ügyletek közösen kialakított áron és mennyiségben fognak lezajlani, melyeket a tőzsde szigorú szabályok szerint rögzít. Magától értetődik, hogy a rögzített ügyletekből visszakövethetőek és megjeleníthetőek múltbeli árfolyamok (J.-H. Chen & mtsai, 2020). Fontos megjegyezni, hogy a stratégiaalkotás során kiemelt jelentősége van az adatszerkezetnek, hiszen ez alapján definiáljuk azt a programot, amit utána az adatfolyamon futtatunk. Tisztában kell lennünk az adatszerkezet korlátaival, például szűrt vagy réseket nem tartalmazó historikus adatok alapján generált algoritmus nem fog megfelelően működni élő kereskedés esetén, így a múltbeli visszatesztelés félrevezető és túlzó elvárásokat fog támasztani (Shi és mtsai., 2022).

A megjelenítés igen változatos lehet. Hooper és mtsai. (2013) szerint a gépi modellezés előtti időkből a minél változatosabb megjelenési módoktól várták a kereskedők, hogy minél pontosabban tudják előre jelezni a trendeket, illetve a piaci fordulatokat. A következőkben a pénzügyi világ által leggyakrabban használt megjelenítési módokat tárgyalom:

Tick-grafikon: A tick az árfolyam változását jelenti, ez a legkisebb egység, melyben az árfolyam változása mérhető. Kiemelt jelentőségű az 1 tick felbontású adatsor, mely nem más, mint a kötéslista (Hooper és mtsai., 2013). Az ebből készített grafikon az összes ügyletet tartalmazza adott árfolyamokon. Jellegéből adódóan ez az árfolyam-ábrázolás legrészletesebb eszköze (2. ábra).

Likvid pénzügyi eszközöknél, nagy ügyletszám esetén a megjelenítés nehezen követhető és értelmezhető. Ugyanakkor az összes megjelenítési módszernek ez az alapja, tick-adatokból származtatjuk őket (Nison, 2001). Illikvid eszközöknél hatékony eszköze a megjelenítésnek, mivel időtől függetlenül megjeleníthetjük az ügyleteket (Hooper és mtsai., 2013). További jelentősége egy-egy speciális esemény nyomkövetésénél van.



2. ábra: Tick adatok megjelenítése CVGI részvényen

*Forrás: TradeStation Inc., saját szerkesztés*

Vonal diagram: A vízszintes tengelyen az időt, míg a függőlegesen az árat ábrázoljuk. Az ábrázolásnál általában a záró értéket jelenítjük meg az adatintervallum minden időszakában, majd ezeket a pontokat kötjük össze (Nison, 2001). Például egy napi adatintervallumot tartalmazó grafikonon a vonal az egyes napok záróárait köti össze (3. ábra).




3. ábra: CVGI részvény vonal diagramja

*Forrás: TradeStation Inc., saját szerkesztés*

A vonaldiagramot kevésbé használjuk, mert más ábrázolási módokkal lényegesen több adat jeleníthető meg.

Bar diagram: Minden adatintervallumot különálló jel ábrázol (4. ábra). A bar diagram lehet időalapú, tick alapú és volumen alapú. Kiválasztjuk intervallumnak az első, majd utolsó ügyletet, a legmagasabb és a legalacsonyabb áron végbement ügyletet, majd ezt a módszert ismétljük a teljes adathalmazra (Hooper és mtsai., 2013). Ezt hívjuk nyitó-magas-alacsony-záró adatrendszerzésnek (OHLC).



4. ábra: Bar intervallum értelmezése


*Forrás: Saját szerkesztés*

Kitüntetett időintervallum a napi grafikon, mely tartalmazza minden napra a nyitó, legmagasabb, legalacsonyabb és a záró árakat. Jelentősége arra vezethető vissza, hogy mielőtt a számítástechnika meghódította volna a tőzsdei kereskedést egy szűk körön kívül nagyon nehézkes volt adatokhoz jutni (Smith, 2004). A legtöbb ember a nyomtatott sajtóból értesült a részvények előző napi záró áráról és ez alapján hozta meg befektetési döntéseit.

A 90-es évek végén a számítási kapacitás, grafikus megjelenítés rohamos fejlődésével – a grafikus operációs rendszerek széles körű elterjedésével lehetőség nyílt az ügyletek tetszőleges időintervallumra történő megjelenítésére (Poitras, 2009). A mai modern kereskedési szoftverek akár a másodperc alapú megjelenítésre is képesek.

Ez a rendszerezési elv szűrt adatokat tartalmaz, hiszen a 4 árfolyamon kívül semmi más információnk nincs, mi történt az intervallumban. Az 5. ábra a szemlélteti a napon belüli és a napi árfolyamot. Ebből látható, hogy napi kereskedés során az árfolyam számos alkalommal áthaladt a nyitó árfolyamon. Ebből napi bontásban semmi nem látszik, sőt a napi bar alapján egy

felfelé mutató mozgást vízionálunk, ugyanakkor, ha megnézzük az árfolyam napon belüli alakulását, láthatjuk, hogy jelentős volt a bizonytalanság az irányt illetően.




5. ábra: Árfolyam értelmezése napon belül és napi intervallumban

*Forrás: TradeStation Inc., saját szerkesztés*

Az adatokat bar diagramba rendezhetjük még tetszőleges számú tick és volumen alapján is. Például 100 tick alapú rendezés alapján a grafikon minden egyes eleme 100 ügyletet fog tartalmazni. Hasonlóan 1000 volumen alapú bar diagram minden egyes egysége 1000 részvény/kontraktus kereskedését fed le és jeleníti meg.

Japán gyertyák: Ezt a megjelenítési módot már az 1600-as évek óta használták a Japán határidős rizstőzsdéken (J.-H. Chen & Tsai, 2020). Azért nevezték őket gyertya-diagramnak, mert megjelenése hasonlít kanóccal rendelkező gyertyára (6. ábra).

Ez a megjelenítési mód nagy jelentőséget tulajdonít a nyitó és az záró áraknak és azok kapcsolatának (J.-H. Chen & Tsai, 2020). A gyertyadiagram ugyanazokat az árfolyam adatokat használja, mint egy bar diagram. A gyertya „vastag” részét „testnek” nevezik, a nyitó és záró árfolyam közötti tartományt képviseli (Hung & Chen, 2021). Megjelenítés szerint lehet üreges (zöld) - a záró árfolyam magasabb volt, mint a nyitott árfolyam, vagyis az árak emelkedtek, jelentése bika piacot feltételez (Hung & Chen, 2021). Ezzel szemben a teli testtel rendelkező gyertya medve piacot szimbolizál – a záró ár alacsonyabb volt, mint a nyitóár. A test feletti vékony vonal a magas, a test alatti vékony vonal az alacsony árat jelöli.



6. ábra: Üres és teli gyertya ábrázolása

*Forrás: Saját szerkesztés*

Mondhatni, hogy a legelterjedtebb megjelenítési mód, hiszen vizuális megjelenítése nagyban könnyíti a véleményalkotás és értelmezés folyamatát. A zöld és piros test ábrázolás azonnal lehetővé teszi, hogy felmérjük, hogy az időszakokban az árak hogyan viselkedtek (7. ábra).



7. ábra: Trendek megjelenítése gyertya diagrammal E-mini S&P 500 határidős szerződésen

*Forrás: TradeStation Inc., saját szerkesztés*



Kagi diagramok: Egymáshoz kapcsolódó függőleges vonalak sorozatát jeleníti meg, amelyek vastagsága és iránya a piacon zajló eseményektől függ (Hooper és mtsai., 2013). Tehát amikor a piac ugyanabba az irányba mozog, mint egy korábbi Kagi vonal, a vonal meghosszabbodik. Amikor a piac az ellenkező irányba mozog az előre definiált mértékben, egy új, ellenkező irányú vonal jelenik meg. A vonal színe és szélessége megváltozik, amikor a Kagi vonal áttör egy korábbi magas vagy mély árat (Hooper és mtsai., 2013). A diagramok nem időalapúak, hanem az árfolyam alakulása alapján épülnek fel (8. ábra).



8. ábra: E-mini S&P 500 ábrázolása Kagi diagramon 10 pontos visszafordulási árral

*Forrás: TradeStation Inc., saját szerkesztés*

Kase bar diagram: Úgy néznek ki, mint egy hagyományos bar diagram, azzal az eltéréssel, hogy az egyes oszlopok méretét egy céltartomány-érték határozza meg; az összes bar megközelítőleg azonos méretű (Hooper és mtsai., 2013). Ennek a megjelenítési módszernek az előnye, hogy a bar-ok egyenlő valós tartományokon alapulnak, ami figyelembe veszi azokat a réseket, amelyek az előző bar zárása és a bar tartományába eső aktuális magas vagy alacsony szint között előfordulhatnak (Hooper és mtsai., 2013). A másik előnye, hogy a bar-ok csak valós adatok felhasználásával készülnek. Ha az alapul szolgáló adatokban rések vannak, akkor ezek szintetikus bar-ok létrehozásával nem kerülnek kitöltésre, így jól láthatóak a tényleges kereskedés valós tartományai (9. ábra).



9. ábra: E-mini S&P 500 ábrázolása Kase diagramon 10 pontos intervallum árral

*Forrás: TradeStation Inc., saját szerkesztés*

Pont és ábra diagram: Már az 1800-as évek végén használták. McAllan (2016) szerint ez a diagramkészítési módszer az árváltozásokra összpontosít az idő és a mennyiség kizárásával, arra fókuszál, hogy az ár hol van a korábbi szintekhez viszonyítva (10. ábra). Ezt szem előtt tartva döntéstámogatást nyújt abban, hogy az árfolyam egy trend folytatását, megfordulást vagy kitörést jelent-e. Ezen túlmenően a pont és ábra diagramok kiszűrik a jelentéktelen árfolyam változásokat (Nison, 2001). Ez a diagramtípus két fontos dologban különbözik a bar diagramoktól: A felhasználó által meghatározott minimális érték alatti árfolyam fordulatok nem jelennek meg – ezáltal kiszűrik az árak statikusságát. Az árfolyam változások függőleges oszlopok sorozataként jelennek meg, ahol a növekvő trendek X-ek oszlopaként, a csökkenő trendek pedig az O-k oszlopaként jelennek meg (McAllen, 2016). Az X oszlop azt mutatja, hogy a kereslet meghaladja a kínálatot, az O oszlop pedig azt, hogy a kínálat meghaladja a keresletet. A blokkok méretét szintén a felhasználó adja meg, mely az ár minimális növekedésére vagy csökkentésére vonatkozik, amely szükséges ahhoz, hogy X-et vagy O-t adjunk az oszlophoz (McAllen, 2016). Például, ha a blokkméret 0,5, akkor az X oszlopban minden alkalommal, amikor az ár 0,5-tel növekszik, egy X kerül hozzáadásra. Az O oszlopban minden alkalommal, amikor az ár 0,5-tel csökken, egy O-t adjunk hozzá. A visszafordítási összeg az ár felfelé vagy lefelé történő változására utal, amely egy új oszlop létrehozásához szükséges.



10. ábra: E-mini S&P 500 ábrázolása pont és ábra diagramon 2 pontos doboz és 5 pontos visszafordulási árral

*Forrás: TradeStation Inc., saját szerkesztés*

### 2.1.2. Határidős szerződések

Ha belegondolunk ezek a piacok logikus okok miatt alakultak ki. Vegyük például a mezőgazdasági termékeket. Nehézkesen lenne megoldható, hogy az összes termelő egyszerre vigye el a termékét egy adott helyszínre. De talán ennél is fontosabb, hogy a határidős piacok hídként funkcionálnak a termelők és a felhasználók között (Refco Private Client Group, 2005). Példaként tekintsük egy gazdálkodó helyzetét, aki egy adott év tavaszán elveti a terményt. Az előző évek tapasztalatai, a vetőmag előállító ajánlásai és a termőföld minősége alapján a gazdálkodó kalkulálható mennyiségű kukoricát fog betakarítani szeptemberben. Bizonytalanság van azzal kapcsolatban, hogy a gazdálkodó mennyit kap a kukoricáért. A szűkösség éveiben viszonylag magas árakat lehet elérni, különösen, ha a gazda nem siet az eladással (Hull, 2017). Másrészt a túlkínálat éveiben előfordulhat, hogy a kukoricát kell megsemmisíteni, mert tárolása drágább, mint az aktuális árfolyama. A gazdálkodó egyértelműen nagy kockázatnak van kitéve, ráadásul a növénytermesztési folyamat minden mozzanatát előre finanszíroznia kell beleértve a saját megélhetését is (Schwager, 2017).

A másik oldalon egy kukorica feldolgozó vállalat áll, amelynek folyamatosan szüksége van kukoricára. A társaság legnagyobb kockázata a kukorica árfolyama. Egyes években a túlkínálati helyzet kedvező árakat teremthet, ugyanakkor más években a rossz termés miatt az árak túlzott mértékűek lehetnek. Ezek az erraticus piaci folyamatok ellehetetlenítik a termelés tervezhetőségét és fenntarthatóságát (Schwager, 2017).

A megoldás egyértelműen adja magát, a gazdálkodót össze kell hozni a vállalattal lehetőleg már a tavasz folyamán. A gazdálkodó ekkor eladja, míg a vállalat megveszi kölcsönösen előnyös árfolyamon a szeptemberben aratandó kukoricát. Ez azt jelenti, hogy egyfajta határidős szerződésről tárgyalnak. A szerződés lehetőséget biztosít mindkét fél számára, hogy kiküszöböljék azt a kockázatot, amellyel a kukorica bizonytalan jövőbeli ára miatt szembe kell nézniük (Schwager, 2017).

Összegezve a határidős piacok csökkentik a szezonálisból eredő extrém árfolyammozgásokat, folyamatos bevételt teremtenek a termelőknek, transzparenciát és biztonságot nyújtanak a piaci szereplőknek csak a legfontosabb jellemzőket említve.

A határidős piacok előzőekben megismert szereplőit fedezeti kereskedőknek nevezzük (CME Group, 2013). Az eladók, vagyis a termékek előállítói finanszírozni tudják magukat azáltal, hogy rögzített áron előre el tudják adni az árujukat, míg a vevők sok hónappal előre be tudják biztosítani a vételi árakat. Egy gyárnak létfontosságú a folyamatos az alapanyagellátottság, de a termelés hatékonysága és gazdaságossága miatt az az optimális, ha árak az előre tudja tervezni. Hieronymus (2022) szerint a kereskedéssel együtt a spekuláció is megjelent a határidős piacokon és mind a mai napig velünk is maradt, ugyanakkor e nélkül a másodlagos piaci kereslet nélkül a piac nem tudna hatékonyan működni. A spekulánsok – vagyis azok az entitások, akik se nem termelők, se nem felhasználói ezeknek a termékeknek – extra likviditást biztosítanak a piac minden szereplőjének cserébe a spekulánsok elfogadják a piaci kockázatokat és megpróbálnak profitálni az árfolyammozgásokból (Williams, 1987).

A határidős piacokon való kereskedésnek számos előnye van, melyeket egyéb piacok nem képesek biztosítani, ilyen a likviditás. A határidős piacok likviditásából következően az elcsúszás és a jutalék mértéke a szerződés értékéhez képest minimális, mely lehetővé teszi, hogy olcsón és hatékonyan lehessen ügyleteket kötni. Szintén előnyként említhetjük a volumet, hiszen a határidős piacokon, egy-egy szerződés értéke eléri vagy meghaladja a százezer dollárt, így a mennyiség nem korlátozó tényező (Hull, 2017). Kiszámolható, hogy ha egy határidős piacon napi több millió szerződés cserél gazdát, az milyen óriási összegeket jelent.

A modern pénzügyi világ mind a mai napig egyik legfontosabb eszköze a határidős szerződések (un. *futures contracts*). Ez egy olyan megállapodás, amely egy eszköz vételére vagy eladására irányul egy bizonyos áron, egy adott időpontban a jövőben. A szerződések minden részlete

standardizált, mely lehetővé teszi, hogy ezekkel a papírokkal az úgynevezett határidős piacokon kereskedni lehessen (Schwager, 2017).

Új szerződés kidolgozásakor a tőzsde részletesen meghatározza a két fél közötti megállapodás pontos jellegét (Refco Private Client Group, 2005). Pontosan definiálja az eszközt, a szerződés méretét, azt, hogy egy szerződés keretében mennyit kell a termékből leszállítani, az hol és mikor történik (Refco Private Client Group, 2005). Néha alternatívákat adnak meg a szállítandó termék minőségére vagy a szállítási helyekre. Ha a szerződésben meghatározott eszköz egy termék vagy árucikk, akkor a piacon elérhető minőség meglehetősen eltérő. A standardizáláskor ezért fontos, hogy a tőzsde kikösse az áru elfogadható besorolását vagy besorolásait (CME Group, 2013). Ezzel szemben határidős ügyletekben szereplő pénzügyi eszközök általában jól meghatározottak és egyértelműek.

A szerződés mérete határozza meg az eszköz mennyiségét, amelyet le kell szállítani. A likviditás és a termék népszerűsége szempontjából ez fontos tulajdonság. Ha a szerződés mérete túl nagy, akkor azok a kereskedők, akik viszonylag kis kitétségeket akarnak fedezni, nem tudják használni azt. Másrészt, ha a szerződés mérete túl kicsi, a kereskedés költséges lehet, mivel minden kereskedett szerződés költséggel jár (Refco Private Client Group, 2005).

A szállítás helyét szintén a tőzsde szabja meg. Ez különösen fontos a jelentős szállítási költségekkel járó áruk esetében. Minden határidős szerződésre pontos szállítási hónap vonatkozik (CME Group, 2013). Meghatározzák a hónapon belüli pontos időszakot, amikor a szállítás teljesíthető. Sok határidős ügylet esetében a szállítási időszak az egész hónap. A szállítási hónapok szerződésenként változnak, és a tőzsde választja ki a piaci szereplők igényeinek megfelelően. Egy adott időpontban több hónapra szóló szerződéssel is lehet kereskedni, ez lehet legközelebbi szállítási hónapra szóló és persze a többi azt követő szállítási hónapra vonatkozó is (CME Group, 2013). A tőzsde határozza meg, hogy mikor kezdődik a kereskedés az adott hónap szerződésében és természetesen azt is, hogy melyik az utolsó nap amikor egy adott szerződésre még lehet ügyletet kötni. A kereskedés általában néhány nappal az utolsó szállítási nap előtt szűnik meg (CME Group, 2013).

A határidős kontraktus árfolyama eltér az alapjául szolgáló eszköz spot árfolyamától. Ez logikus, hiszen a piacnak be kell áraznia azokat a várakozásokat, hogy a szerződés lejáratakor hol fog elhelyezkedni a spot árfolyam (Hull, 2017). A szállítási időszakához közeledve a két árfolyam közeledik egymáshoz. A piaci várakozásoktól függően a határidős árfolyam elhelyezkedhet a spot árfolyam felett, de alatta is.

A megkötött határidős ügyletek közül nagyon kevés vezet a szerződésben részletezett eszköz tényleges leszállításához (Hull, 2017). A legtöbb ügyletet lejárat előtt lezárják. Ennek ellenére

az esetleges szállítás lehetősége határozza meg a határidős árat. Ezért fontos a szállítási eljárások megértése.

A szállítási időszakot a tőzsde határozza meg, és szerződésenként változik. A teljesítés időpontjáról az eladási pozícióval rendelkező fél dönt. Amikor úgy dönt, hogy szállít, akkor brókere értesítést ad ki a szállítási szándékáról a tőzsdei elszámolóháznak. Ez a közlemény tartalmazza, hogy hány szerződést szállítanak ki, és áruk esetén azt is meghatározza, hogy hol és milyen minőségben kerül szállításra (CME Group, 2013). A tőzsde ezután kiválaszt egy vételi pozícióval rendelkező felet a szállítás elfogadására. Az általános szabály az, hogy a szállítási szándékról szóló értesítést a legrégebbi pozícióval rendelkező félnek adja át. A vételi pozícióval rendelkező feleknek el kell fogadniuk a szállítási értesítéseket. Előfordul azonban, hogy az értesítések átruházhatók, általában fél óra áll rendelkezésre, hogy másik felet találjanak vételi pozícióval, aki kész elfogadni az értesítést tőlük (CME Group, 2013).

Áru esetében az átvétel általában azonnali fizetés ellenében raktári bizonylat elfogadását jelenti, ekkor a vevő viseli az összes raktározási költséget is. Pénzügyi határidős ügyletek esetén a szállítás általában átutalással történik. Minden szerződés esetében a fizetett ár általában a legutolsó elszámoló ár. Ha a tőzsde előírja, ez az ár a minőséghez, a szállítás helyéhez és egyéb feltételekhez igazodik. A teljes szállítási folyamat a kézbesítési szándékról szóló értesítéstől a kézbesítésig általában két-három napot vesz igénybe (Schwager, 2017).

A szállítás során három kritikus nap van: Az első értesítési nap, az utolsó értesítési nap és az utolsó kereskedési nap. Az első értesítés napja az az első nap, amelyen a szállítási szándékról szóló értesítést be lehet nyújtani a tőzsdére, nyilvánvaló, hogy az utolsó értesítési nap az utolsó ilyen nap. Az utolsó kereskedési nap általában néhány nappal az utolsó értesítési nap előtt van. A vételi pozícióval rendelkező befektetőnek az első értesítési nap előtt le kell zárnia a szerződéseit annak érdekében, hogy az áru leszállításának kockázatát elkerülje (Schwager, 2017).

A határidős szerződések túlnyomó többsége nem vezet teljesítéshez. Ennek az az oka, hogy a legtöbb befektető úgy dönt, hogy a szerződésben meghatározott szállítási időszak előtt lezárja pozícióit. A határidős szerződések feltételei alapján történő szállítás vagy átvétel gyakran kényelmetlen és bizonyos esetekben meglehetősen költséges (Hieronymus, 2022). Ez még a fedezeti kereskedőkre is igaz, aki ténylegesen meg akarja venni vagy eladni a határidős szerződés alapjául szolgáló eszközt. A fedezeti kereskedők általában inkább lezárják a határidős pozíciót, majd a szokásos módon megvásárolja vagy eladja a terméket. Egy pozíció lezárása technikailag eredetivel ellentétes ügylet megkötését jelenti (Hieronymus, 2022).

Egyes határidős pénzügyi ügyletek készpénzben kerülnek elszámolásra, mert kényelmetlen vagy lehetetlen a mögöttes eszköz leszállítása (CME Group, 2013). Például az S&P 500-ra vonatkozó

határidős kontraktus esetében a mögöttes eszköz leszállítása 500 részvényből álló portfólió átadásával járna. Ebben az esetben elszámoló ár megegyezik az alapul szolgáló eszközök részvénypiaci árfolyamával a kereskedés nyitásakor vagy zárásakor az adott napon.

A tőzsde egyik kulcsszerepe a kereskedés megszervezése, hogy elkerülhetőek legyenek a szerződészegések (Hull, 2017). Ennek fő eszköze a fedezeti számlák. Egy szerződés megvásárlásának időpontjában nincs szükség arra, hogy a termék teljes értékével rendelkezünk, hiszen a teljesítés, vagyis a termék leszállítása is csak a jövőben fog megtörténni. A vásárlás pillanatában elég az alapletétet befizetnünk a fedezeti számlára. Ez jellemzően a kontraktus értékének 10-15%-a. A határidős szerződések fontos tulajdonsága ez a tőkeáttétel (Hull, 2017). Az alapletét pontos összegét természetesen a tőzsde határozza meg. A kereskedési nap végén megállapítják az aznapi elszámoló árat, melynek jelentősége a fedezeti számlán jelenik meg. Ugyanis, ha az árfolyam csökken, akkor a vételi pozícióval rendelkező befektető fedezeti számlájáról ténylegesen levonják csökkenés értékét. Amennyiben az ügyfél nem rendelkezik megfelelő egyenleggel, akkor pótlólagos befizetést írnak elő. A befizetés a megszabott határidőre nem érkezik meg, akkor az elszámolóház likvidálja a pozíciót (Refco Private Client Group, 2005). Hasonlóképpen, ha az árfolyam emelkedik, a vételi pozícióval rendelkező ügyfelek fedezeti számlái jóváírást kapnak elszámolóháztól. Természetesen a befektető jogosult az induló letétet meghaladó egyenleget felvenni (Refco Private Client Group, 2005).



11. ábra: Arany 2023 decemberi határidős szerződés árfolyama

*Forrás: TradeStation Inc., saját szerkesztés*

A határidős szerződés minden eleme pontosan specifikált, így az elnevezésük és a kereskedési kódjaik is. A részvényekhez hasonlóan ezeknek is van egy rövid két-három karakteres megjelenítési kódjuk, ehhez kapcsolódik hozzá a lejárat hónap – melyet latin betűvel jelölünk, illetve az utolsó két karakter az évet jelöli. Például GCZ23 az arany 2023 decemberi határidős szerződésének (11. ábra) jelölése, melyet beírva egy kereskedési platformba ténylegesen elérhetjük és kereskedhetjük azt.

Mivel a határidős szerződések kereskedése egy időpontban elkezdődik és egy meghatározott napon pedig véget ér, ezért árfolyamának a megjelenítése csak erre a néhány hónapos időszakra korlátozódik. Az elemzés megkönnyítése végett számos kereskedési platform az aktuális („front month”) határidős szerződések árfolyamát összefüzi és visszamenőlegesen kiigazítja. Ennek segítségével lehetőség nyílik az árfolyamot összefüggően vizsgálni és elemezni. Erre nagy szükség van, hiszen a határidős szerződések kockázata elméletileg végtelen (Hull, 2017). Ebben az esetben ez a vételi pozíciókra is igaz, mivel az árfolyam negatívba is fordulhat. Erre nem is olyan régen precedens is mutatkozott, amikor a Covid járvány kitörésekor az olaj aktuálisan lejárató (CLK20) szerződésének árfolyamát -37 dollár alatt számolták el (12. ábra).



12. ábra: Olaj határidős szerződés 2020 május

*Forrás: TradeStation Inc., saját szerkesztés*

Ez volt az első és egyetlen alkalom az olaj kereskedése során, hogy egy szerződés negatív értéken zárt. A negatív árat a tároló kapacitások telítettségével magyarázták (Prabheesh és mtsai., 2020). De bármi is volt az oka, a fenti példa nagyszerűen mutatja be azt a kockázatot,



melyet a határidős szerződések magukban hordoznak. A lejárat előtt sokan abban a hitben vették nulla közeli értéken ezeket a szerződéseket, hogy az árfolyama nem mehet nulla alá és egy esetleges visszafordulás során hatalmas hozamot tudnak realizálni. Ugyanakkor a kontraktus specifikációi egyértelműen tisztázzák a negatív árfolyamok lehetőségét. Az óvatlan kereskedők a fedezeti számlájukon lévő összeg tízszeresét is elveszíthették, melyet az elszámolóházak akár peres úton is, de behajtanak rajtuk.

### **2.1.3. Fundamentális elemzés és az azon alapuló kereskedési módok**

Számos elmélet foglalkozik azzal, hogy megbecsülje a részvények árfolyamváltozásait. Két nagy csoportjuk a fundamentalisták és a technikai elemzők. Az előbbiek értéket keresnek, elemzik az adott vállalat nyilvánosan elérhető beszámolóit, pénzügyi arányszámait és ez alapján hozzák meg befektetési döntéseiket, melyek jellemzően hosszabb távra szólnak (McAllen, 2016). Ez az idegen szóval kifejezve „old school” kereskedési modell, mely szerint hiszünk az adott vállalatban, annak menedzsmentjében, hogy hosszú távon fenntartható növekedési pályán fognak működni. A másik csoport a technikai elemzők. Ők az árfolyamot és a kereskedési volument elemezve minősítik a jelenlegi árfolyamot alacsonynak vagy magasnak és ezek alapján hozzák meg kereskedési döntéseiket (McAllen, 2016).

A 90-es évek végéig a fundamentális elemzés uralta a pénzügyi piacokat. A lakossági befektetők a közép- és hosszú távra koncentráltak, mert valós idejű információhoz jutni és pláne azokat valós időben feldolgozni egy szűk kereskedői kör kiváltsága volt (Kaufman, 2013). A világ többi része legkorábban másnap olvashatta a nyomtatott jelentéseket a pénzügyi sajtóban (Investors’ Business Daily, Barron’s Weekly Report). Az Internet széles körű elterjedése kisbefektetők milliói előtt nyitotta meg a pénzügyi piacokat (Thomsett, 1999). A technológiai fejlődés és a számítási kapacitás növekedése olyan számításokat és automatizálást eredményezett, amely korábban lehetetlen volt.

A fundamentális elemzés és a vállalati pénzügy összetett tudományok. Úgy gondolom azonban, hogy néhány mutató tanulmányozásával bármely vállalat pénzügyi helyzetét fel tudjuk mérni. Nagyon fontos megjegyezni, hogy a fundamentális elemzés egésze soha nem vetíti előre a jövőt. Thomsett (1998) szerint megmutatja a cég múltját és jelenlegi állapotát, és semmi sem garantálja, hogy a múltbeli trendek a jövőben is folytatódni fognak.

A múlt és a jelen ismerete hasznos betekintést ad a trendekbe és a lehetséges kimenetek valószínűségébe. Lehetővé teszi számunkra, hogy következtetéseket vonjunk le, és általános képet kapjunk a cégről (Brealey és Mtsai., 2020).

Nagyon fontos az is, hogy a mutatókat teljes összefüggésrendszerként vizsgáljuk. Például a 10%-os nettó haszonkulcs önmagában stabil érték, de ha visszanézünk az elmúlt időszakokra,

és az érték 20%-ról csökken fokozatosan, akkor ez mindenképpen intő jel, mert a jövedelmezőség csökkenő tendenciát mutat.

De nemcsak a történeti adatok sorozatait hasonlítjuk össze egymással, hanem kiterjeszthetjük kutatásunkat annak ellenőrzésére, hogyan teljesítenek a versenytársak, és hol helyezkednek el az adott szektorban. Fontos megjegyezni, hogy az arányoknak nem feltétlenül kell állandóan növekedniük. A végtelen növekedés hamis elvárás. Még a jól menedzselte multinacionális vállalatok is elérik a határaikat valamikor. A hosszútávú stabilitás ugyanolyan vonzó lehet, mint a növekedés (Thomsett, 1999).

A fundamentális elemzés befektetési fókuszja a belső tényezőkön van. Az ezekből az elemzésekből származó adatok felhasználása, valamint az ebből eredő stratégia- és portfóliótervezés a vállalatok belső adataira, így a hosszú távú vállalati teljesítményre és potenciálra támaszkodik, nem pedig trendekre és külső tényezőkre.

A megfelelő mutatókon alapuló hatékony elemzések biztosíthatják, hogy a portfólió lejáratí értéke nagyobb, vagy legalább egyenlő legyen a kezdeti befektetés százalékában megadott szinttel (Fabozzi, 2009).

A fundamentális elemzés egy olyan módszer, amellyel a vállalat részvényeinek belső értékét gazdasági, ipari és pénzügyi tényezők vizsgálatával mérik (Kovács & Tetrák, 2019). A piactorzító hatások kiszűrésével és a nyilvánosan elérhető információk, például az általános gazdasági feltételek, iparági elemzések és a vállalat fundamentumainak értékelése felhasználásával a módszer felhasználható a részvényárfolyam meghatározására (Lam, 2017). A módszer alkalmazása során tehát figyelembe kell venni a cég pénzügyi helyzetének, gazdasági környezetének, eszközeinek, adósságainak és gazdálkodásának jellemzőit (Y.-J. Chen és mtsai., 2017).

A fundamentális elemzés alkalmazása során a korábbi kutatások különböző megközelítéseket javasoltak az elemzésben szereplő indikátorok kiválasztására. Thawornwong és Enke (2004) adaptív pénzügyi és gazdasági változók bevonását javasolja az elemzésbe, amelyeket mesterséges neurális hálózatok segítségével választanak ki. De számos tanulmány foglalkozik a közösségi média befolyásoló hatásával. Bollen és Mtsai. (2011) tanulmányukban azt vizsgálták, hogy a Twitter-bejegyzéseknek van-e befolyásos erejük, vagy felhasználhatók-e a tőzsde előrejelzésére.

A releváns mutatók meghatározásával a tőzsdei előrejelzés pontossága növelhető. Az arányszámok a szervezet mögöttes teljesítményét különböző teljesítmény-perspektívákon keresztül vizsgálják, beleértve a jövedelmezőséget, az eszközhasználatot, a likviditást, a tőkeáttételt, az értékelést és a növekedési perspektívát (Thawornwong & Enke, 2004).

#### 2.1.4. Technikai elemzés

A pénzügyi eszközök kereskedésekor nagyon sok információ áll rendelkezésére. Ezek közül pedig az ár és a kereskedési volumen a legfontosabbak.

A történelem során sokan próbálkoztak olyan matematikai formulák kidolgozásával, melyek segítségével az árfolyammozgások megjósolhatóvá válnak.

A technikai elemzés az értékpapírok értékelésének módszere (Bandy, 2015). Arra a feltételezésre támaszkodik, hogy a piaci adatok, mint például az ár, a mennyiség, a volatilitás külön-külön vagy kombinálva használhatók a jövőbeni trendek előrejelzésére (Bandy, 2015). A fundamentális elemzőkkel ellentétben nem veszik figyelembe a belső értéket. Úgy vélik, hogy pontosan meg tudják jósolni a jövőbeni trendeket, a múltbeli árfolyammozgások alapján. Feltételezik, hogy a piac működési mechanizmusai tükröződnek az adatokban, lehetővé téve számukra, hogy előre jelezzék, mikor emelkedik vagy esik az árfolyam (McAllen, 2016).

A technikai elemzés során a múltbeli árfolyamokból és azok matematikai transzformációiból próbálunk következtetni a jövőbeni mozgásokra, mert az alapvetés szerint ezek a múltbeli mozgások ismétlődni fognak (McAllen, 2016). A technikai elemzés három felvetésen alapul. Az első, hogy minden, amit a piac ismer az tükröződik az árfolyamban. Az adott értékpapírt minden pillanatban azon az árfolyamon kereskedik, amennyit az ér, vagyis az árfolyam tükrözi az összes keresleti és kínálati tényezőt (Schwager, 2017). Az árfolyamdiagram szemlélteti az összes piaci résztvevő együttes cselekedeteit és az elemzők fel tudják ismerni a piaci szereplők ezen cselekedeteit anélkül, hogy tudnák miért teszik azokat. Az árfolyamokat nagyrészt a jövőbeni eseményekre való felkészülés mozgatja (Bandy, 2015). A fundamentális elemzésnek a hosszú távú trendek alakulásában van jelentősége. Mivel adott eszköz értékéről alkotott elképzelések folyamatosan változnak, az árak változnak. A második felvetés, hogy az árak trendekben mozognak (Bandy, 2015). Minden likvid piacot a kereslet és a kínálat alapvető törvényei szabályoznak. Ameddig a kereslet meghaladja a kínálatot az árak emelkedni fognak, tehát az árfolyam emelkedése folytatódik. Bandy (2015) szerint amikor elérjük azt a pontot, ahol egyre több szereplő válik motiválttá az eladásban a trend megfordul és az árfolyamok csökkenni fognak.

A technikai elemzés harmadik alapelve, hogy a történelem ismétli önmagát (Bandy, 2015). Vagyis a korábbi árfolyamok tanulmányozása jelentős betekintést nyújt az adott piac belső életébe. Kétségtelen, hogy bizonyos minták különböző időpontokban ismétlődnek a különböző diagramokon. Ezek a minták csupán az összes piaci szereplő reményeinek, félelmeinek és elvárásainak összegét tükrözik (McAllen, 2016).

A technikai elemzés nagyrészt objektív megfigyelésen alapul. Ha figyelembe vesszük, hogy mit tudunk valójában, szemben azzal, amit a piaccal kapcsolatos eseményekről mondanak nekünk,

akkor kezdünk rájönni, hogy az egyetlen igazság az árból fakad. Az ár az egyetlen dolog, amiért fizetünk a piacon, ezért ez a legfontosabb tényező, amelyet elemzésünk során figyelembe kell venni (Bandy, 2015).

Elemzőként a piaci résztvevők millióinak halmozott hatását figyeljük meg, hogy előre jelezzük, jövőbeli viselkedésük hogyan fogja befolyásolni az árak mozgását (Schwager, 2017). McAllan (2016) szerint ha megértjük az emberi természetet, megérthetjük a piaci mozgásokat.

### **2.1.5. Indikátorok bemutatása és csoportosítása**


Az indikátorok olyan számadatok sorozata, melyet az adott instrumentum árfolyamára alkalmazott matematikai formulát felhasználva származtatnak. Fő funkciójuk, hogy megpróbálja definiálhatóvá tenni az árfolyam-mozgásokat, illetve láthatóvá tenni a ciklikusságot és a piaci mintákat (Bandy, 2015).

A piaci szereplők viselkedését indikátorok vezérlik, amelyek a piac állapotjelzőiként is értelmezhetők (Bihary & Víg, 2020). Be- és kilépési pontokat nyújtanak adott pénzügyi eszköz kereskedéséhez (Nassar, 2006). Elmondható, hogy az indikátoroknak önbeteljesítő erejük van, ami azt jelenti, hogy ha elég sokan használják őket és minél több szereplő hozza meg ugyanazt a döntést ugyanabban az időpontban, akkor az hatással lesz az árra, ezáltal az indikátor működése bizonyítottnak tekinthető (McAllen, 2016).

A történelem során sok ezer népszerű indikátor került kifejlesztésre a legkülönbözőbb módszerek segítségével. Ezek legtöbbször matematikai és valószínűség-számítási modelleken alapul, ugyanakkor léteznek heurisztikus indikátorok is (Y.-J. Chen és mtsai., 2017). Például a telihold ciklusai alapján való kereskedéssel meglepő sikereket lehet elérni.

A mai tőzsdei világban több ezer népszerű indikátor létezik, a céltom a következőkben egy általános elképzelés felvázolása indikátor bemutatásával és kategorizálásával, melyeken keresztül a technikai elemzés koncepciója érthetővé válik.

Működési mechanizmus szerint az indikátorokat hat kategóriára lehet osztani, ezeket a 13. ábra mutatja (Fang és mtsai., 2014). A következőkben ismertetem a kategóriákat, illetve egy-egy jellemző indikátort is bemutatok.



13. ábra: Indikátorok csoportosítása

*Forrás: Fang és mtsai., 2014, saját szerkesztés*

Fontos megjegyezni, hogy egyes indikátorok tulajdonságaikból adódóan több kategóriába is besorolhatóak. Például a Bollinger szalag beilleszthető az átlagos visszaállási és a volatilitás alapú kategóriákba is és a felhasználás módja dönti el, hogy a stratégiában minként alkalmazzuk.

**Trendkövető indikátorok:** Felmérik a trendek erősségét és irányát a kiválasztott időintervallumban (Picasso és mtsai., 2019). Jellemzőjük, hogy az aktuális trendet csak késve képesek mutatni, céljuk, hogy tájékoztassanak a trend közelgő változásáról, előre jelezzék a hosszú távú árfolyammozgásokat. Ezen indikátorok használói arra spekulálnak, hogy a meglévő és megállapított trendek a jövőben is folytatódni fognak.

A *mozgóátlag (MA)* célja a trendek kiegyenlítése azáltal, hogy kiszámítja az átlagos záróárát egy adott számú időszakra (Achelis, 2001). Például, a 20 napos mozgó átlag, az elmúlt 20 nap átlagos záróárát jelenti, melyeket minden egyes periódusra az árfolyamdiagrammal átfedően jelenítünk meg. Matematikai trendvonalnak tekinthetőek, amelyek önmaguktól alkalmazkodnak, miközben a piac új kereskedelmi információkkal lát el bennünket (Achelis, 2001). A mozgó átlagok az egyik leghasznosabb és széles körben elterjedt indikátorok, melyet a 14. ábrán a magenta és a cián színű folytonos vonalak mutatnak.



14. ábra: 20 és 200 periódusú mozgó átlagok

*Forrás: TradeStation Inc., saját szerkesztés*

Minél nagyobb periódusra számítjuk őket, annál hosszabb távú trendeket képezünk le velük. Hátrányuk – a legtöbb indikátorhoz hasonlóan –, hogy lassúak és lemaradva követik csak az árfolyamot (Achelis, 2001). Ugyanakkor sokszor bizonyulnak hasznosnak hosszú távú trendek előrejelzésében, főként meredekségükkel és irányukkal adnak iránymutatást a jövőbeli árfolyammozgásokra.

**Átlagos visszaállási indikátorok:** Az átlagos visszaállítás egy pénzügyi elmélet, amely azt sugallja, hogy az árfolyam szélsőséges mozgás után végül visszatér a hosszú távú átlaghoz (Picasso és mtsai., 2019). Ezen indikátorok használói a trend megtörését várják és visszafordulási pontokat keresnek.

*Bollinger szalag:* John Bollinger által 1980-as években kifejlesztett mutató lehetővé teszi egy adott instrumentum volatilitásának és relatív árszínvonalának összehasonlítását egy adott időszak viszonylatában (Bollinger, 2002). Az indikátor három görbéből áll össze, melyek sávokat alkotnak és közrefogják az árfolyamgrafikont (15. ábra):

- A középső szalag az alap, ami egy egyszerű mozgóátlag (SMA)
- A felső szalag =  $SMA(TP,n) + m \cdot \sigma[TP,n]$   
(Az SMA értékéhez hozzáadjuk a szórás kétszeresét.)
- Az alsó szalag =  $MA(TP,n) - m \cdot \sigma[TP,n]$

(Az SMA értékéből kivonjuk a szórás kétszeresét.)

- $TP = (\text{magas ár} + \text{alacsony ár} + \text{záró ár}) \div 3$ ;  $n = \text{periódusok száma}$ ;  $m = \text{szórások száma}$



15. ábra: Bollinger szalag alkalmazása

*Forrás: TradeStation Inc., saját szerkesztés*

Az indikátor segít azonosítani az extrém piaci feltételeket. Amikor az eszköz ára a Bollinger szalag alsó sávja alá esik, az árak túlságosan sokat estek, és visszapattanhatnak. Ennek ellenkezője, amikor az ár a felső sáv fölé tör, akkor visszalépés esedékes (Bollinger, 2002).

A sávok túlvett/túleladott mutatóként való használata az ár átlagos visszafordulásának koncepcióján alapul.

**Momentum indikátorok:** Méri az árfolyam egyirányú mozgásának erősségét egy adott időszakon keresztül (Ehlers, 2004). Segítséget nyújtanak azon pontok megtalálásában, ahol a piac megfordulhat. Az ármozgások relatív erősségét mutatják, de figyelmen kívül hagyják azok irányultságát. Az ilyen mutatókat trendkövető indikátorokkal kombinálva lehet legjobban hasznosítani.

*Sztochasztikus oszcillátor:* Momentum indikátor, amely összehasonlítja egy értékpapír adott záróárát egy bizonyos időszakon belüli árfolyam tartományával (Nassar, 2006). 1950-es évek végén fejlesztette ki George Lane. Tervei szerint a sztochasztikus oszcillátor a részvény záróárának elhelyezkedését mutatja a részvények magas és alacsony árfolyamaihoz viszonyítva egy bizonyos időszakon, jelzi, hogy az oszcillátor követi az ár sebességét vagy lendületét (Ehlers, 2004). A sztochasztikus oszcillátorok az árakat 0-tól 100-ig terjedő skálán mérik, a 80

feletti értékek azt jelzik, hogy az eszköz túlságosan drága, a 20 alatti mérések pedig azt, hogy túlságosan olcsó (Ehlers, 2004). Ezek azonban nem mindig jelzik a közelgő fordulatot. A nagyon erős trendek hosszabb ideig fenntarthatják az indikátor magas és alacsony értékeit. Ehelyett a kereskedőknek a sztochasztikus oszcillátor változásaira kell figyelniük (Ehlers, 2004). Számítása:

- Sztochasztikus oszcillátor = %K =  $\frac{(C-L_n)}{(H_n-L_n)} \times 100$
- C = aktuális periódus záró ára, L<sub>n</sub> = az előző n periódus legalacsonyabb ára, H<sub>n</sub> = az előző n periódus legmagasabb ára



16. ábra: Sztochasztikus indikátor alkalmazása

*Forrás: TradeStation Inc., saját szerkesztés*

A 16. ábrán jól láthatók az előzőekben megfogalmazott gondolatok. A 20 alatti és 80 feletti indikátor értékek nem minden esetben jelzik előre az árfolyam emelkedését.

**Forgalom alapú mutatók:** Főleg a forgalmi adatokat dolgozzák fel és transzformálják matematikai formulákkal (Sezer & Ozbayoglu, 2018). A forgalom az értékpapír vevői és eladói között egy adott időszakban kicserélt részvények vagy szerződések teljes számát jelenti. Sok kereskedő úgy gondolja, hogy ha nagyobb volumen kíséri az árfolyamváltozást, az érvényesebb és tartósabb lesz (Sezer & Ozbayoglu, 2018).



VWAP: Forgalommal súlyozott átlagár. Egyre népszerűbb mutató, volumennel súlyozza az átlagos árat. Számítása az alábbi képlet alapján történik:

- $VWAP = (TÁ * \text{forgalom}) / \text{napi összes forgalom}$
- $TÁ = (\text{magas ár} + \text{alacsony ár} + \text{záró ár})/3$



17. ábra: VWAP indikátor alkalmazása

*Forrás: TradeStation Inc., saját szerkesztés*

A 17. ábrán magenta színű vonal a VWAP indikátort mutatja. Amennyiben a VWAP emelkedik és az árfolyam felett helyezkedik el, akkor az árfolyam emelkedésére, ellenkező esetben csökkenésre számítunk.

**Volatilitás alapú indikátorok:** A technikai mutatók ezen csoportja segít mérni egy eszköz árfolyamának hirtelen – és gyakran szélsőséges – változásának valószínűségét, ebből következik, hogy ezen mutatók nem jelzik az irányt, viszont a volatilitás mérésével hasznos kiegészítői más indikátornak és kereskedési stratégiáknak (Patton & Sheppard, 2015).

**ATR:** Ez a technikai mutató kiszámítja egy részvény átlagos ártartományát egy adott időszakra vonatkozóan. Minél magasabb az ATR érték, annál nagyobb a volatilitás. Számítása az alábbi képlet alapján történik:

- első periódusra:  $ATR = \left(\frac{1}{n}\right) \sum_i^n TR_i$ , ahol  $TR_i$  a teljes tartomány adott időszakra,  $n$  pedig az időszakok számát jelenti.
- további periódusokra:  $ATR = \frac{ATR(n-1) + TR}{n}$

A 18. ábra az ATR indikátor alkalmazását mutatja be. Látható, hogy magasabb ATR értékekhez nagyobb árfolyammozgás tartozik. Általában kilépési stratégiáknál használják a pozíció és az elért nyitott nyereség védelme érdekében (Patton & Sheppard, 2015).



18. ábra: ATR indikátor alkalmazása

*Forrás: TradeStation Inc., saját szerkesztés*

**Szint alapú indikátorok:** Ezek az árfolyamból számított szintek a piaci szereplők kollektív cselekedeteit képviselik, vagyis, hogy a vevők és az eladók lépései adott árszinteken támogatást vagy ellenállást válthatnak ki. Ezek a szintek azután a belépési és kilépési pontok finomhangolására, valamint a kockázatkezelésre használhatók.

A *pivot pontok* egyszerű matematikai képletek, melyeket alkalmazva az adott nap bizonyos árfolyamaira előre tudjuk vetíteni, hogy a következő kereskedési napon az árfolyam mely értékek között mozoghat (Person, 2013). Továbbá a feltételezés szerint a pivot pontok természetes támaszként és ellenállásként fognak viselkedni. A pivot pontok bármely időperiódusra kiszámíthatók, de a legelterjedtebb és ebből következően a legfontosabb mégis a kereskedési nap alapján számított értékek. Történetüket tekintve ezeket a képleteket a nyolcvanas években találták ki a tőzsdén ülő brókerek, hogy lássák azt, hogy a következő kereskedési napon az árfolyam körülbelül milyen értékek között mozoghat (Person, 2004).

A pivot pontok számításánál három fontos értéket veszünk figyelembe, ezek a periódusra vonatkozó alacsony-, magas- és záró ár (Person, 2004). Ezek kétségkívül meghatározóak, hiszen

ez a három ár egyértelműen tükrözi az összes piaci szereplő időszakra vonatkozó akaratát és viselkedését. Ezek alapján a pivot pontok számítása a következő:

- $\text{Pivot pont} = (\text{napi maximum ár} + \text{napi minimum ár} + \text{záró ár}) / 3$
- $\text{Ellenállás1} = R1 = 2 \times \text{Pivot pont} - \text{napi minimum}$
- $\text{Ellenállás2} = R2 = \text{Pivot pont} + \text{napi maximum ár} - \text{napi minimum ár}$
- $\text{Támasz1} = S1 = 2 \times \text{Pivot pont} - \text{napi maximum}$
- $\text{Támasz2} = S2 = \text{Pivot pont} - \text{napi maximum ár} + \text{napi minimum ár}$



19. ábra: Pivot pontok megjelenítése az árfolyamgrafikonon

*Forrás: TradeStation Inc., saját szerkesztés*

A 19. ábrán leolvasható az árfolyam és a pivot pontok is. Egy ilyen diagramot megnézve az embernek az a benyomása támad, hogy az esetek döntő többségében az árfolyam valóban a kereskedési nap elején már ismert pivot pontok között halad, mint ahogy ezt „megjósoltuk”.

A pivot pontok abból a feltételezésből indulnak ki, hogy ha az árfolyam eléri azt, akkor arról vissza fog pattanni (Person, 2013). Vagyis támaszként és ellenállásként viselkednek. Ha az árfolyam emelkedik és az adott pivot pontot alulról közelíti, akkor ellenállásról beszélünk, a feltételezés szerint arról vissza fog pattanni és újból lefelé fog mozogni bizonyos ideig. Amennyiben az árfolyam esik a pivot pontot fentről fogja elérni, mely szintről az árfolyam visszapattan és újra emelkedni fog (Person, 2013).

A valóságban természetesen előfordul az is, hogy az ár eléri a pivot pontot és mint kés a vajon halad át rajta. Az elmélet szerint ebben az esetben az addig támaszt képező pivot pont inntől kezdve ellenállásként fog viselkedni (Person, 2004).

#### **2.1.6. Diszkrecionális kereskedési módok**

A pénzügyi eszközökkel való kereskedést a szabályrendszer alapján két nagy csoportra oszthatjuk. Az első a diszkrecionális módszerek a másik pedig a szisztematikus kereskedés (Kissell, 2020).

A diszkrecionális elméletben hívők a tőzsdei kereskedésre szinte már, mint művészetre tekintenek és nem egzakt tudományként. A szabályok szubjektív alkalmazása miatt nem tudjuk szimulálni az ügyletek kimenetelét, nem tudjuk megmondani, hogy az adott diszkrecionális stratégia profitábilis e, hiszen a piaci körülmények ismerete csak a jelenben lehetséges (Hieronymus, 2022).

És ebben az esetben még nem vettük figyelembe a hasonló súllyal felmerülő pszichológiai faktorokat, melyek kétségtől a kezdő kereskedő ellen fognak dolgozni, akár tudomásunk van róluk, akár nincs (Douglas, 2000).

Kaufman (2013) szerint a technikai vagy fundamentális elemzés segítségével végzett analízis segít kialakítani azt, hogy mit kellene a piacnak csinálnia a jövőben. Ugyanakkor ennek helyességére, bekövetkezésére nincs garancia. A különböző elemzési módszerek segíthetnek és védelmet nyújthatnak a katasztrofális események bekövetkezése ellen, illetve megmondják azt is, hogy mikor nincs igazunk egy adott kereskedési döntés után. A diszkrecionális kereskedés az elemzési módszerek mellett egyenlő mértékben fontos a kereskedési pszichológia megfelelő alkalmazása, mivel olyan egyedi döntéseket sorozatát kell meghoznunk, melyet mentális, fizikai állapotunk és jólétünk erősen befolyásolni fognak (Kaufman, 2013).

Ezen kereskedési mód figyelembe veszi azt, hogy az piac minden pillanatban egyedi állapotban van, mely ugyan hasonlíthat egy múltbeli mintára, de sosem ugyanolyan (Hooper és mtsai., 2013). Így a jelenlegi minta kereskedése sem lehet teljesen ugyanolyan. Elengedhetetlen az egyéni vélemény és nézetek kialakítása, vagyis az, hogy mit is gondolunk a jelenlegi piaci trendekről, illetve az adott eszköz belső életéről. Hooper és mtsai. kihangsúlyozzák a sikeres kereskedés alapjaként a konzisztenciát. Ez a konzisztencia nem feltétlenül jelenti azt, hogy minden egyes minta előfordulásakor kereskednünk kell, sokkal inkább, hogy az ügylet- és kockázatmenedzsment minden esetben ugyanúgy történjen (Hooper és mtsai., 2013). A kereskedések időzítése kritikus fontosságú és lehetetlen, hogy mindig igazunk legyen. A nyertes ügyleteket olyan módszer szerint kell menedzselni, melyek biztosítják azt, hogy a lehető legkésőbb zárjuk le őket, maximalizálva a profitunkat. A veszteseket pedig gyorsan azonosítani

és likvidálnunk kell. Wang (2015) szerint ha ez a titok, akkor messze ez a legértékesebb, amit a diszkrecionális kereskedés során meg kell tanulnunk. A fentieket szem előtt tartva a kereskedő ezzel a megközelítéssel jobb esélyeket szerezhet (Wang, 2015). Miután megtanulta a kereskedés szabályait, kialakította saját szabályrendszerét és stratégiáit, további sikere a hozzáálláson és a gondolkodásmódon múlik.

Kaufman (2013) azt gondolja, hogy a tanulási folyamat nehezebb része a kereskedés „belső játékában” való elmélyülést jelenti, mert a diszkrecionális módszer szerint kereskedésben nem működik a szisztematikus megközelítés. Ha így lenne, akkor annyit kellene tennünk, hogy ugyanazt a módszert alkalmazzuk minden alkalommal pontosan ugyanúgy (Kaufman, 2013). Ebben a kérdésben véleményem szerint igazuk van a diszkrecionális elméletben hívőknek. Egyetlen kereskedési stratégia sem működik örökké, mivel a piaci folyamatok állandó és folyamatos változásban vannak.

### **2.1.7. Algoritmikus kereskedés anatómiája**

Már a 2000-es évek elején adott volt a lehetőség bármely tőzsdéhez való kapcsolódáshoz direkt brókereken keresztül. A kapcsolat számítógép (és akkor modem) segítségével történt, melyből egyenesen következett a kereskedési modellek és stratégiák automatizálása, hiszen a számítógépek programozhatósága lehetővé tette ezt (Kissell, 2020). Az egyszerű programok kiváltották az ember általi felügyeletet, pontosabban és gyorsabban tudtak végrehajtani komplex rendelés-beviteli folyamatokat, illetve nem befolyásolták őket külső tényezők, mint például az érzelmek (Chang és mtsai., 2022). Ezekből alakult ki az algoritmikus kereskedés, mely pontosan definiált kód vagy program alapján zajlik (Hatch és mtsai., 2021). Lehet manuális végrehajtású, mely esetben a vételi-eladási megbízások bevitele a kereskedő feladata. Ennek akkor van létjogosultsága, ha a program kevés ügyletet generál, például havonta néhányat. Ilyen esetekben a rendszer folyamatos felügyelete több időt venne igénybe, mint az ügyletek manuális bevitele (Emami, 2022). Automatikus végrehajtás esetén a számítógép folyamatosan futtatja a kódot és figyeli az árfolyamot. Amikor a programban az összes feltétel teljesül, akkor vételi-eladási megbízásokat küld a tőzsdére (Kissell, 2020). Kissell (2020) könyvében kiemeli, hogy a fejlett algoritmusok visszacsatolással rendelkeznek, azaz tudják, hogy mi történik az ügyletekkel, rálátnak a brókerszámlára, kockázatokat és kereskedési mennyiségeket tudnak számítani és menedzselni.

Tőzsdei kereskedésnél az ügyletek kimenetele nyereséges vagy veszteséges lesz, a lényeg abban rejlik, hogy összességében több nyereség keletkezzen, mint veszteség (Hatch és mtsai., 2021). Szándékosan nem azt írtam, hogy többször nyerjünk, mint veszítsünk, hiszen előfordulhat, hogy

a stratégia kevesebbszer fog nagyobb összegű profitot realizálni, míg többször veszít kisebb összeget, vagy éppen fordítva.

A kereskedési program definiálására szinte végtelen kombináció létezik (Chan, 2013). Kis túlzással élve akár egy nap-hold együtt állást is figyelembe vehetünk, amennyiben az a múltbeli adatokon való tesztelés során egynél nagyobb profit faktort eredményez.

A programozott kereskedés alapja, hogy bár a jövőt nem ismerjük, de az emberi természet és ezen keresztül az árfolyamok mozgása ismétli önmagát. Kissel (2020) szerint az ismétlés nem pontosan ugyanolyan minta mentén fog lezajlani, éppen ezért a sikeres kereskedési modelleknek képesnek kell lennie az eltérések kezelésére, illetve bizonyos tűrésen belül kell működniük.

Sajnos előre nem tudjuk megmondani azt, hogy a szabályrendszer, mely nyereséget generál adott pénzügyi eszközön meddig fog működni, mi az a pont, amikor a pénzügyi eszköz belső élete annyit változik, hogy a múltbeli árfolyammozgásokon letesztelt kód a valós idejű kereskedés során veszteséget termel (Davey, 2014). Azt gondolom minden rendszerfejlesztőnek ez a legnagyobb félelme, mivel a piaci mozgások, körülmények megváltozását nem könnyű számszerűsíteni és egyáltalán észrevenni.

Csak remélhetjük, de nem tudhatjuk előre, hogy a teljesítmény lejtmenetbe váltása az algoritmus természetéből adódik, és hamarosan fordulóponthoz érünk, vagy túl sok paraméterrel rendelkezünk, melyek a piaci körülmények változásához nem tudnak hozzásimulni és már nem teljesítik a nyereségesség feltételeit (Dubey és mtsai., 2022).

Az algoritmusok írása egy ötlettel indul. Az ötletet ezután finomítjuk és átkonvertáljuk valamilyen programozási nyelvre, majd lefuttatjuk múltbeli kereskedési adatokon. Ha az eredmény, azaz az ügyletek összessége nyereséges, akkor indulhat az optimalizálás, melynek célja a tőke görbe kisimítása. A folyamat akkor optimális, ha a tőke görbe minél jobban illeszkedik az egy meredekségű egyenesre vagyis Pearson korrelációja minél közelebb van a maximális értékhez (Brunton & Kutz, 2019).

Egyszerű ötleteknél nem kell sok paraméterrel számolnunk, ugyanakkor, de ha már 4-5 változóval dolgozunk az optimalizálás bonyolultsága exponenciálisan fog nőni, így vagy az erőforrásainkat növeljük, vagy alkalmazhatunk genetikusan algoritmusokat (Macedo és mtsai., 2020).

Ezeket úgy kell elképzelnünk, hogy egy listába felsorolunk tőzsdei indikátorokat azok összes lehetséges változójával. A program ezek után genetikusan algoritmusok segítségével szimulálja az összes indikátor összes változójának lehetséges értékét az árfolyamban ismétlődő minták után kutatva (Chung & Shin, 2020). Chung és Shin (2020) tanulmányában kimondja, hogy a mai számítási kapacitás mellett a folyamat genetikusan algoritmusok használata nélkül lehetetlen lenne, hiszen sok milliárd kombinációt kellene egyesével átfuttatni az árfolyamokon.

A szimuláció végeztével sorba rendezzük a kapott rendszereket, és ezeket finomítjuk tovább. A végeredmény az emberi agy számára logikailag nehezen értelmezhető kód lesz, mivel a genetikus algoritmus olyan kombinációkat fog találni, mely az adott pénzügyi eszközön a legtöbb ugyanolyan kimenetelű ügyletet eredményezte (Nicholls & Engelbrecht, 2019).

Véleményem szerint a genetikus algoritmusok által talált kereskedési programok sérülékenyek, mert túl sok változó bevonásával találnak meg optimális modelleket. A piaci környezet rezgéseit a fix paraméterek nem képesek lekövetni, ezért legjobb esetben is ezeket a programokat időszakosan újra kell gondolni és optimalizálni.

Algoritmikus kereskedés esetén a kockázatokat maximum csökkenteni és menedzselni tudjuk akár a diverzifikáció által, vagyis, hogy egymás mellett több olyan algoritmus fut melyek semleges vagy negatív korrelációval rendelkeznek (Kissell, 2020).

Miután létrehoztunk egy algoritmust, mely az összes tesztet sikeresen vette, elkezdődhet az éles környezetben való kereskedés.

### **2.1.8. Az algoritmikus kereskedés ellenségei**

Emami (2022) tanulmányában kiemeli, hogy a piaci környezet, az árfolyam belső életének változása lassú, de biztos folyamat és valószínű, hogy ezek a változások érdemben fogják befolyásolni a kereskedési eredményeket.

Egyszerű példát hozva a múltbeli árfolyam trendeket elemezve azt találtuk, ha a részvényünk értéke a megelőző napon 2 dollárral csökkent, akkor a következő kereskedési napon többször fordult vissza, mint haladt volna tovább. Ez a szabályrendszer remekül működött az elmúlt 5 évben az adott pénzügyi eszközre. Ugyanakkor, ha árfolyam belső élete számottevően változik – például kétszeresére nő, vagy akár felére csökken, akkor a lefektetett szabályrendszerünk nem fog ugyanolyan hatékonyságú ügyleteket eredményezni. Összegezve, a szabályaink a már ismert árfolyam mozgásokra vannak optimalizálva, érte ez alatt a mozgás nagyságát, volatilitását és időbeliségét. Előre lehetetlen megmondani, hogy az árfolyam belső mozgásainak mekkora változása mellett tud még hatékonyan működni a programunk, minthogy azt sem tudjuk, hogy ezek mikor következnek be (Kaufman, 2013). Természetesen ezek a változások nem törvényszerűen negatívak, ugyanúgy elképzelhető, hogy a megnőtt volatilitás a profitabilitás növekedésével és a tőke görbe harmonikusabbá válásához fog vezetni (Davey, 2014).

Az előbbi kockázatokat csökkenthetjük azzal, hogy összetett pénzügyi eszközökkel kereskedünk, melyek sok egyéni részvényt foglalnak magukba (Lam, 2017). Ilyenek lehetnek a tőzsdeindexek, vagy az úgynevezett ETF-ek (elektronikusan kereskedett alapok). Az indexek és a hozzájuk kapcsolódó határidős szerződések előnye, hogy egy-egy részvény belső életének változása csak minimális hatással van rájuk (Fabozzi, 2009). Továbbá a nagyfokú likviditás és

diverzifikáltság jellemzi őket. Egy-egy vállalatot érintő iparági változások, negatív hírek, hibás menedzsment döntések a teljes részvénykosár életében csak súlyozottan jelennek meg (Fabozzi, 2009).

Egy kereskedési algoritmus szabályokból épül fel, melyek meghatározzák, hogy az árfolyam vagy akár idő változására hogyan reagálunk. A szabályok paramétereit használják a számításaikhoz, melyek változtatása hatással van mind a múltbeli, mind pedig a jövőbeli kereskedési teljesítményre (Zhong & Enke, 2019). Ha a rendszert fixen és mereven a múltbeli adatokra szabjuk, akkor a rendszer teljesítménye sokkal rosszabb lesz az élő kereskedés során. Fontos elkerülni a túl-optimalizálást, de egzakt definíció nem létezik az optimalizálás mértékére vonatkozóan (Brunton & Kutz, 2019). Bár adott programról könnyen el tudjuk dönteni, hogy elég rugalmas-e, tehát azt meg tudjuk állapítani, hogy nincs túl-optimalizálva. Ennek egyik módszere a paraméterek változtatása. Amennyiben a rendszer a paraméterek változtatásával közel azonos nyereséget és tőke görbét produkál, akkor valószínűleg élő kereskedés során is meg fogja állni a helyét (Domowitz & Yegerman, 2005). Ugyanakkor, ha a paraméterek már mérsékelt változtatása esetén az eredmények összeomlanak, akkor valószínűsíthető, hogy az algoritmus túl-optimalizált. Természetesen a kevésbé optimalizált rendszer alacsonyabb múltbeli profitot fog eredményezni, viszont nagyobb lesz az esély arra, az élő kereskedés random árfolyamadataira rugalmasabban fog reagálni, így az elvárt eredményeket produkálni fogja (Bacidore, 2020).

Véleményem szerint az algoritmikus kereskedés legnagyobb ellensége az emberi természet saját maga. Leggyakoribb példák erre a nyertes ügyletekből való korai kilépés, holott a szabályok ezt nem engedték volna meg, illetve ezzel párhuzamosan a vesztes ügyletek szabályok szerinti lekereskedése. A másik generális hiba az ügyletek közötti válogatás, melynek szintén pszichológiai okai vannak. Ilyenkor fordul elő, hogy a rendszert felügyelő kereskedő leállítja a következő ügylet végrehajtását, mely történetesen a tőke görbe megfordulását jelentette volna számára. Az emberi érzelmek algoritmikus kereskedésből való teljes kizárására kell törekedni (Douglas, 2000). Olyan szabályokat kell alkotni, melyek a program futásába csak előre meghatározott esetekben engedik meg az interakciót (Scarpino, 2019). A rendszerre érzelemmentesen kell tekinteni, ami nem egyszerű feladat, hiszen a valós ügyleteknél tényleges nyereség, rosszabb esetben veszteség keletkezik. Nyilvánvaló, hogy a nyereség kezelése egyszerűbb, egy jó indulással, a profit görbe felfutásával könnyebben kezelhetők a visszaesések is, hiszen technikailag olyan profitot veszítettünk el, amelyet a rendszer saját maga generált. Más a helyzet akkor amikor visszahúzással indul az élő kereskedés. Ilyenkor az ember természetéből adódóan folyamatosan megkérdőjelezi a rendszer hitelességét - ekkor még inkább fontos a szabályok betartása. Természetesen előfordulhat teljes kudarc, bármennyire is jól működött az



algoritmusunk a múltbeli adatokon való tesztek során, mivel a jövőbeli árfolyammozgások ismeretlenek. Kissel (2020) szerint az ilyen esetekre érdemes előre meghatározni, hogy mennyi az a maximális veszteség, melyet tolerálni tudunk. Amikor ez bekövetkezik a rendszert meg kell állítani és levonni a megfelelő következtetéseket.

A rendszerfejlesztők gyakran az éles kereskedés alatt szembesülnek azzal, hogy az eredmények nagyban térnek el a szimulációtól, mégpedig úgy, hogy minden a szabályok szerint történt. Ennek egyik oka lehet, hogy a fejlesztés során nem tulajdonítunk nagy jelentőséget a brókereknek fizetett jutaléknak, és talán egy még fontosabb jelenségnek az elcsúszásnak. A jutalék előre is jól számítható, hiszen erről bármikor találunk pontos információkat, és egyszerűen korrigálhatjuk a szimulációs eredményeket. A nagyobb problémát az elcsúszás okozza, mely nem más, mint a különbség kívánt és a tényleges vételi vagy eladási ártól (Kissell, 2020). A kereskedés aukciós rendszerben történik, melyet a 20. ábra szemléltet.

ID	Bid	Size	Time	ID	Ask	Size	Time
CME	4474.50	136	08:37:12 AM	CME	4474.75	56	08:37:12 AM
CME	4474.25	111	08:37:09 AM	CME	4475.00	90	08:37:12 AM
CME	4474.00	93	08:37:09 AM	CME	4475.25	117	08:37:09 AM
CME	4473.75	100	08:37:09 AM	CME	4475.50	97	08:36:45 AM
CME	4473.50	86	08:37:12 AM	CME	4475.75	94	08:37:07 AM
CME	4473.25	88	08:37:12 AM	CME	4476.00	115	08:37:05 AM
CME	4473.00	116	08:36:42 AM	CME	4476.25	128	08:36:55 AM
CME	4472.75	109	08:36:42 AM	CME	4476.50	119	08:36:34 AM
CME	4472.50	105	08:36:42 AM	CME	4476.75	117	08:36:11 AM
CME	4472.25	101	08:37:09 AM	CME	4477.00	154	08:37:09 AM

20. ábra: Rendelési könyv keresleti és kínálati oldala

*Forrás: TradeStation Inc.*

A keresletet és kínálatot összefésüljük, a keresleti oldal vásárolni szeretne, míg a kínálati eladni. A kötések mindig a legjobb áron történnek, a legelső sorban szembe állítjuk a legjobb vételi ajánlatot a legjobb eladási árral. Ha a két fél árfolyama megegyezik, akkor az ügylet létrejön. Addig nem történik kötés az adott piacon amíg valamelyik fél meg nem adja a másik által kért árat. Likvid eszközöknél a másodperc töredéke alatt sok ügylet megy végbe, akár elcsúszás nélkül is (Zhong & Enke, 2019). Viszont, ha piaci típusú rendeléssel kereskedik a stratégia, mely az ügylet teljesülését garantálja, de az árat nem, akkor biztos, hogy rosszabb árat fogunk kapni (Bacidore, 2020). Ez az elcsúszás a leglikvidebb eszközök esetén megegyezik a legkisebb kereskedési egységgel. Az elcsúszás a vétel és eladás során is jelentkezik, és ez a faktor kereskedési stratégiák nagy részét lehetetlen helyzetbe hozza, mivel az átlagos ügyletenkénti

profit számottevő részét képezi (Théate & Ernst, 2021). Arról nem is beszélve, hogy a piac állapotától, volatilitásától függően az elcsúszás mértéke random változhat, mely megnehezíti az előzetes tervezését.

A 20. ábra által szemléltetett rendelési könyvből látszik továbbá az is, hogy az egyes árszinteken hány résztvevő van és ők milyen mennyiséget kívánnak venni vagy eladni. A rendelési könyv a kereskedési idő alatt folyamatosan nyitva van, vagyis állandó változásban van (Chan, 2013). Ami jelen esetben fontos, hogy amennyiben adott szinten létrejön az ügylet és elfogy az összes keresett-kínált mennyiség, továbbá nincs új rendelés az adott szinten, akkor megnő az elcsúszás mértéke (Chan, 2013). Itt merülnek fel a mennyiségi korlátok. Egy egyszerű példával szemléltetve, tegyük fel, hogy az algoritmusunk 200 részvénnyel kereskedik, de a legmagasabb kínálati és keresleti oldalon ennél kevesebb részvény található, akkor a piaci típusú rendelésünk azt fogja eredményezni, hogy a legjobb szinten megy végbe az ügyletünk, az adott szinten elhelyezkedő volumen, majd a maradék részvényünk egy szinttel lentebbi – rosszabb – áron fog teljesülni. Ez nagyon kényes probléma, hiszen a rendszerbe kalkulált elcsúszás megnő a kereskedési volumen nagysága miatt, és ez a programunk sikerességét befolyásolja.

Napjainkban több tízmillió entitás kapcsolódik a világ legnagyobb tőzsdéihez főként interneten keresztül. A távolság ugyan az internet segítségével leküzdhető, de a szabályok értelmében a rendelési sorban az lesz az első, akinek a rendelése a leggyorsabban jut el a tőzsdére (Kaufman, 2013). Földrajzilag minél közelebb vagyunk a tőzsde szervereihez, annál jobb végrehajtásra számíthatunk. Itt milliszekundumos különbségekről beszélünk. A probléma javítható, ha algoritmusainkat olyan szerveren futtatjuk melyek tőzsde szerverparkjával azonos városban vannak (Scarpino, 2019). Ezzel sok tízmillió végfelhasználó elé kerülünk, akik a világ különböző pontjairól több száz milliszekundumos hátrányban vannak (Scarpino, 2019).

Bármennyire is stabilnak gondoljuk az architektúránkat, a technológia azért van, hogy időnként kudarcot valljon. Ez megtörténhet a mi oldalunkon, például egy szerverleállás, de ugyanúgy előfordulhat a brókerünkénél is, sőt a tőzsde maga sem védett teljesen a technológiai hibák ellen. Ezek a leállások érdemben befolyásolhatják a kereskedésünket, ügyletet veszíthetünk el, de ami talán ennél is rosszabb, hogy beragadhatunk egy ügyletbe, mely komoly eltéréseket okoz a teljesítményben a szimulációhoz képest.

Amikor valaminek a hatására piaci pánik alakul ki és eluralkodik a negatív hangulat, akkor az árfolyamok hajlamosak nagyot esni rövid idő leforgása alatt (Lin, 2018). A kereskedési algoritmus szempontjából mindegy, hogy az áresést mi váltja ki, ami viszont fontos, hogy egy ilyen környezetben ügyleteket végrehajtani szinte lehetetlen. Ez különösen igaz a piaci árfolyamon történt kötésekre, hiszen egy pánik során a rendelési könyvben felborul az egyensúly, rengetegen akarnak eladni, míg vásárolni senki nem akar, a rendelési könyv vevői

oldala teljesen kiszárad, mely az árfolyam összeomlásához vezet (Shi és mtsai., 2022). Shi és mtsai. (2022) tanulmányukban kiemelik, hogy ez egy öngerjesztő spirált indít el, ugyanis az alacsonyabb árszintekhez kapcsolódó előre leadott úgynevezett stop rendelések aktivizálódni fognak, újabb eladási hullámot indítva. Nem beszélve arról, hogy ilyenkor bekapcsolnak az árfolyam esésre spekuláló eladási algoritmusok is, növelve a piaci pánikot. A nagyobb összeomlások ellen a tőzsdék szabályokat vezettek be, bizonyos napon belüli esés után leállítják a tőzsdei kereskedést (Bacidore, 2020). A piaci pánik a kereskedési programunk számára azért különösen veszélyes, mert ilyenkor túlterhelődnek a kommunikációs csatornák, a brókerek rendszerei, sőt még a tőzsde rendszerei is, a rendelés-bevitel lassúvá és nehézkessé válik szimplán azért, mert az architektúra nem arra lett tervezve, hogy mindenki egyszerre és azonnal próbálja a pánik során végrehajtani az ügyletét (Shi és mtsai., 2022). Ilyenkor nem csak rendelés-beviteli problémákkal szembesülünk, hanem az árfolyam adatok is késve jutnak el hozzánk, mely gátolni fogja az algoritmusunk pontos végrehajtását, sőt a legtöbbször a piaci pánik technológiai problémákhoz fog vezetni, a kapcsolat a brókerünkkel összeomlik, a kereskedési szoftver lefagy, és ugyanez igaz a bróker és a tőzsde közötti összeköttetésre is (Schwager, 2017). Az egész folyamatot csak élő kereskedés során lehet megismerni, mert ha megnézünk egy árfolyam diagramot, akkor ugyanolyan mintákat látunk, mint bármikor máskor, csak a mozgások nagyobbak. Erre az a magyarázat, hogy a pánik az általánosan használt diagramokon nem jelenik meg, mert az információ óriási mennyisége miatt szinte mindig szűrt adatokkal dolgozunk (Schwager, 2017).

A piaci pánik élő kereskedés esetén jól észrevehető és definiálható a rendelési könyv legjobb vételi és eladási árfolyam közötti különbség növekedésével (Bacidore, 2020). Amikor ez a rés sokszorosára nő, biztosak lehetünk benne, hogy a piacon valami történik, melyre nem vagyunk felkészülve. Természetesen ebben az esetben az élő kereskedési eredményeink szintén el fognak térni a szimulációtól.

### **2.1.9. Portfólió diverzifikáció**

Lam (2017) szerint a professzionális pénzmenedzserek folyamatosan a kockázatelemzés dimenziójában élnek - nekik a kockázatok minimalizálása mellett elérhető maximális hozam jelenti a biztonságot.

A portfólió diverzifikálása talán a kockázatcsökkentés legegyszerűbb, de egyben leghatékonyabb módszere (Silva és mtsai., 2015). Amennyiben van egy nyereséget termelő algoritmusunk mennyire lehetünk biztosak abban, hogy közép vagy rövid távon hasonló eredményekkel fogunk kereskedni. A historikus eredmények bármennyire is jók, és bármennyire is hiszünk a kereskedés alapelveiben nem tudhatjuk, hogy ismeretlen árfolyamokon rendszerünk

hogyan fog teljesíteni (Day és mtsai., 2023). Éppen ezért célszerű több stratégiával kereskedni, mely rendszerek múltbeli korrelációja maximum enyhe fokú (Day és mtsai., 2023). A hangsúly nem a sok stratégiával való kereskedésen van, hanem azon, hogy azok között ne legyen korreláció. Ha egy algoritmus nem teljesít jól élő kereskedésben, annak vesztesége csak adott súllyal jelenik meg a teljes portfólió teljesítményében. Azt gondolom a korreláció mentes diverzifikáció alkalmazása egyértelmű. Sajnos a korrelációra is igaz, hogy a múltbeli eredmények nem feltétlenül igazak a jelenre és a jövőre. Tehát elképzelhető, hogy a múltbeli adatok alapján nem korreláló stratégiák élő kereskedési eredményei korrelálni fognak (Rahiminezhad Galankashi és mtsai., 2020). Ez különösen igaz váratlan piaci események, pánik során, amikor minden eszközosztály árfolyama egy irányba mozog - ilyen események voltak a 2008-as pénzügyi válság, vagy a 2020-as Covid járvány is (Shi és mtsai., 2022).

A fenti portfóliót a legegyszerűbben úgy érhetjük el, ha egymással kapcsolatban nem álló eszközosztályokkal kereskedünk (Day és mtsai., 2023). Például a határidős búzára nincs hatással a határidős ezüst szerződések, azok egymástól függetlenek, árfolyamukat független tényezők befolyásolják. Valószínű, hogy a két szerződés árfolyamának belső élete annyira eltér egymástól, hogy ugyanaz a stratégia biztosan nem kereskedhető mindkettőn, így az különböző eszközökre különböző stratégiákat kell fejlesztenünk.

Korreláció-mentességet nem csak különböző piacokon alkalmazott algoritmusokkal lehet elérni. Az algoritmus ki és belépési pontjainak változtatása, de az adatszerkezet változtatása is hatékony módszerek (Domowitz & Yegerman, 2005). Természetesen ebben az esetben meg kell bizonyosodni arról, hogy az új algoritmus szolid, robusztus eredményeket fog produkálni.

A diverzifikáció előnye - a kockázatok csökkentésén kívül – a profit görbe simítása, vagyis harmonikus és kiegyensúlyozott teljesítmény elérése. Minél több egymástól független stratégiánk van, a profit görbe annál jobban fog illeszkedni az egy meredekségű egyenesre. A profit görbe simításából egyenesen következik, hogy a maximális veszteségünk is kisebb lesz, mivel az egyedi stratégiák lokális maximális vesztesége időben eltolva fog jelentkezni (Bacidore, 2020).

A több stratégiával, több eszközön való kereskedés további előnye, hogy nagyobb volumenben tudunk kereskedni (Bacidore, 2020). A 2.1.8. fejezetben tárgyaltam a kereskedés ellenségeit. Ha a kereskedési mennyiségünket több stratégián és eszközön osztjuk meg, akkor az elcsúszás jelentősen csökkenhet, hiszen adott időpontokban kisebb mennyiséggel kereskedünk. Ugyanez igaz a technológiai problémákra, melyet megjelenése csak az éppen aktív rendszereinket érinti.

### **2.1.10. Kockázat- és profitmenedzsment**

Bármilyen stratégia alapján kereskedik valaki a kockázat- és az ügyletmenedzsment minimum ugyanannyira fontos, ha nem fontosabb, mint maga a kereskedési döntés meghozatala (Refco Private Client Group, 2005). A hosszú távú befektetők számára kulcsfontosságú, hogy tudják, hogyan kell értékelni a részvényekkel kapcsolatos kockázatokat (Bihary és mtsai., 2020).

Különböző szabályrendszerek alkalmazása mellett elképzelhető, hogy a fundamentális vagy akár technikai elemzési módszer által generált vételi pont után két ugyanolyan belépési ponttal rendelkező ügyletből az egyik nyertes lesz, míg a másik veszteséget fog realizálni (Kissell, 2020). A kockázatok helyes felmérése, a múltbeli trendek alkalmazása, az emberi tényező mind olyan faktorok, melyek a sikeres kereskedési stratégiák alapjául szolgálnak és fontosabbak annál, hogy milyen eszközzel, milyen árfolyamon kereskedünk (Nassar, 2006). El kell fogadni azt, hogy a kereskedés alapjában véve kockázattal jár. A jó kockázatmenedzsment minimális tőkét kockáztat a maximális haszon elérése mellett (Lam, 2017). Az előző mondás klisének hangzik és az optimum elérése rengeteg akadályba ütközik, melyek a kereskedés jövőbe mutató jellegéből adódóan ismeretlenek. Ennek a kockázatnak több típusa létezik, melyeket előre definiálunk és ismernünk kell. A legelső szinten az ügyletenkénti kockázat helyezkedik el, mely azt az összeget jelenti, melyet hajlandóak vagyunk elveszíteni egy ügyleten (Bacidore, 2020). Technikailag ez lehet egy fixen meghatározott összeg, az árfolyam volatilitása alapján meghatározott szint, vagy az indikátorok bizonyos értékei és ezek kombinációja (Bacidore, 2020). A híres befektető és technikai elemző W.D. Gann tízes szabálya szerint sosem szabad a stratégiára allokált tőke 10 százalékánál többet kockáztatni egy ügyleten (Reddy, 2013). Ez a szabály ma már inkább az 1-2% között mozog. Hiszen ez fogja biztosítani, hogy elég időt tudunk biztosítani a stratégia számára több egymást követő vesztes ügylet kezelésére. Reddy (2013) szerint az ügyletenként kockázat része a pozíciómenedzsment, melynek során meg kell határozunk, hogy az egyes ügyletnél hány részvénnyel/szerződéssel kereskedünk. Stratégiafejlesztés során gyakran elfelejtik kiegyenlíteni a kockázatokat. Schulmerich és mtsai (2015) azt gondolják, ha az ügyletek bekövetkezési sorrendje random, akkor célszerű minden ügyleten ugyanakkora összeget kockáztatni, mivel előre nem tudjuk mely ügyletünk lesz nyereséges vagy veszteséges.

A határidős szerződések lényeges tulajdonsága a nagy tőkeáttétel, mely miatt a modellépítés gyakran egy szerződésre történik, mely nyilván az élő kereskedés során oszthatatlan, így a kiegyenlítetlen kockázatok a véletlenre bízzák, hogy melyik ügyleten mekkora nyereség/veszteség keletkezik, mely az ügyletek random megoszlása miatt katasztrofális veszteségeket is okozhat egy amúgy robusztus stratégiának (Hull, 2017).

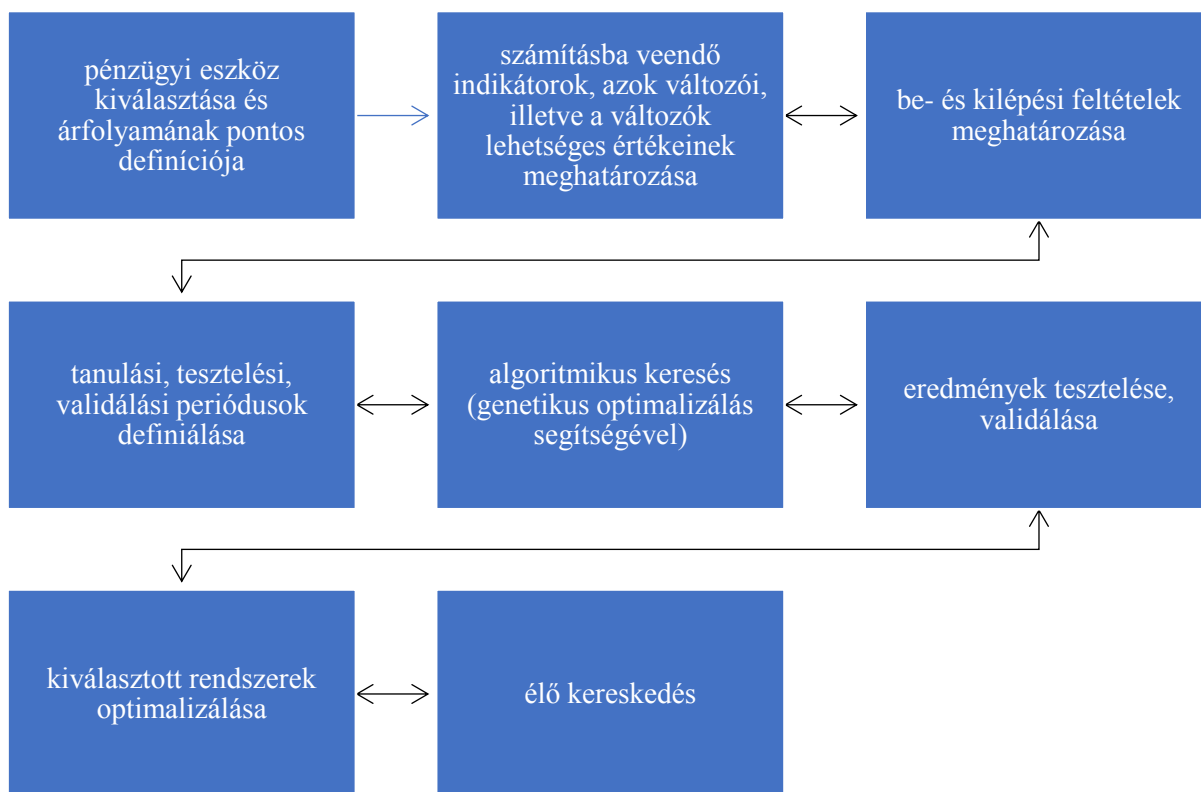
Ezt követi a stratégia kockázat, mely azt a maximális veszteséget jelenti, melyet hajlandóak vagyunk kockáztatni a stratégia végrehajtása során (Kissell, 2020). Ezt szintén előre meg tudjuk határozni, hiszen a historikus adatokból ki tudjuk számítani a múltbeli veszteségek maximumát. Érdeemes feltételezni azt, hogy az élő kereskedés során veszteségünk legalább ilyen mértékű lesz, sőt célszerű a múltbeli maximális veszteséget biztonsági faktorról felültervezni, melynek mértéke egyéni preferenciától és kockázattűrő képességtől függ. Adott stratégia alokációjának tervezésnél elfogadott a maximális múltbeli veszteség négyszerese plusz a kereskedéshez szükséges letét összegének használata. Hatékonyan alkalmazható a Monte Carlo elemzés, mely szimuláció egy valós rendszer jellemzőinek és viselkedésének megismétléséből vagy másolásából áll. Az ügyletek sorrendjének véletlenszerű ismétlése drámaian eltérő nyereséget és maximális veszteséget mutathatnak (Davey, 2014). A folyamatot többször ismételve megkapjuk a maximális veszteségek összesített eloszlását, melyhez rendelt valószínűségekkel eldönthetjük az egyéni preferenciáknak megfelelő maximális veszteség értékét (Davey, 2014). A legfelső szinten a portfólió kockázat helyezkedik el, mely veszteség a diverzifikált portfóliónk maximális vesztesége, melynek elérésekor a kereskedést megállítjuk (Kissell, 2020). A portfólió kockázat mértékét hasonlóan határozzuk meg, mint a stratégia kockázatot. Nemcsak a kockázatot, a profitot is menedzselni kell (Schulmerich és mtsai., 2015). Ez szintén történhet ügylet, stratégia és portfólió szinten. Célja ugyanúgy a kockázat csökkentése, a már megszerzett nyitott nyereség védelmét jelenti. Pszichológiailag az egyik legnehezebben kezelhető kereskedési esemény, ha a szabályrendszer betartása miatt egy nyertes ügylet – az árfolyam megfordulása miatt - veszteségbe torkollik. Az árfolyam megfordulását kiváltó esemény lehet a mozgás kifulladás, volatilitást jelentősen megemelő piaci hír érkezése (Schulmerich és mtsai., 2015). Bármelyik esemény is következzen be a profitmenedzsment történhet előreutató célárak alkalmazásával, mely az a profit érték, amely az adott piacon az ügyleteken átlagban elérhető volt (Schulmerich és mtsai., 2015). A buktató a múlt időn van, hiszen ezt az összeget a múltbeli adatok alapján határozzuk meg. Amennyiben a volatilitás a jövőbeni mozgásokon alacsonyabb lesz, a célárat kevesebbszer érjük el, tehát a profitunk alacsonyabb. Hasonlóan nagy volatilitás esetén túl korán érjük el a célárat és túl nagy lesz a kihagyott profit összege. A másik profitkezelési módszer a mozgó veszteség módszer alkalmazása, melynek során matematikai módszerekkel az árfolyam mozgásához igazodva csökkentjük a maximális veszteség értékét (Schulmerich és mtsai., 2015). Ennek eredményeként az ügylet először nullszaldóssá válik, majd biztos nyertessé. Természetesen az már az árfolyam alakulásától függ, hogy az ügylet lezárásakor a profit összege mekkora lesz. A gépi modellépítésbe az említett módszerek beépíthetők, így a kockázat- és profitmenedzsment alkalmazásával optimalizálhatjuk az algoritmusunk működését.

## 2.2. Gépi modellépítés

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 árfolyam adatokon 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 biztosított eredmények jónak minősülnek és megfelelően nagy generációt és populációt választva biztosan elmondhatjuk, hogy globális optimumhoz közelítő eredményeket kapunk (Nicholls & Engelbrecht, 2019).



21. ábra: A rendszerépítés legfontosabb aspektusai

*Forrás: Genetic System Builder, saját szerkesztés*

A 21. 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.

### 2.2.1. Az adatfolyam definiálása

A modellgenerálás első lépése az adat és az adatszerkezet meghatározása. Van egy kezdeti ötletünk, hogy valamely piacon szeretnénk a modellt megépíteni. Ennek számos oka lehet, a személyes preferenciától kezdve az adott eszköz volatilitásáig, likviditásáig, szezonáliságáig. Nem elég a szektort megadnunk, hanem ki is kell választanunk egy pénzügyi eszközt. Dahal és mtsai. (2023) szerint az árfolyam, likviditás, a tőzsdei elérhetőség olyan faktorok, melyek befolyásolják, az adatszerkezetet. Például egy napi néhány ezer kötéssel rendelkező részvényen nincs értelme nagy frekvenciájú kereskedési modelleket építeni. Így amikor kiválasztottuk az eszközt és megismertük a tulajdonságait, akkor következhet az adatszerkezet definiálása. Itt szembesülünk azzal, hogy azt szinte végtelen módon definiálhatjuk (J.-H. Chen & Tsai, 2020). Az árfolyamok megjelenítését és értelmezését a 2.1.1. fejezetben részletesen bemutattam. A számos szabványosítási módszer közül a legegyszerűbb és legkönnyebb az időalapú rendszerezés. Az árfolyammozgások időbeli megjelenítéséhez meghatározzuk az intervallumot



(például 5 perc). Ezután kiválasztjuk ennek az első intervallumnak az első, majd utolsó ügyletét, a legmagasabb és a legalacsonyabb áron végbement ügyletet, majd ezt a módszert ismétljük a teljes adathalmazra. Ezt hívjuk nyitó-magas-alacsony-záró adatrendszerezésnek (OHLC) (McAllen, 2016). Ennél a lépésnél már eldől, hogy milyen időtávú modelleket fogunk építeni. Minél nagyobb az intervallum, annál hosszabb távú lesz a rendszerünk, illetve a kereskedési frekvencia annál kisebb lesz.

### 2.2.2. Indikátorkosár, indikátorok és változók

A 21. ábra szerint a modellépítés következő lépése a technikai indikátorok kiválasztása, melyek segítségével definiáljuk a keresendő mintánkat. Amikor a mutató értéke eléri a korábban megfigyelt értékeket, feltételezzük, hogy hasonló árfolyammozgás fog bekövetkezni (Macedo és mtsai., 2020). Tulajdonképpen így az indikátorok belépési és kilépési pontokat biztosítanak (Nassar, 2006). Manapság több ezer népszerű indikátor létezik, mely hatványozza a rendszerfejlesztés összetettségét. Természetesen nem elég kiválasztani az indikátorokat, tisztában kell lenni működésükkel és definiálni kell a paramétereinek a lehetséges értékeit is. Célszerű létrehozni egy indikátorkosarat, melybe beletartozik több száz indikátor. Meghatározzuk, hogy a döntési kritériumhoz hány indikátor kombinációját kívánjuk felhasználni egyszerre. Érthető okok miatt több száz indikátort egyszerre nincs értelme számításba venni, hiszen a lehetséges kombinációk száma már három indikátor esetében is elérheti a  $10^{30}$ . Kühl és mtsai. (Kühl és mtsai., 2022) szerint a hatékonyság érdekében célszerű a modell indikátorainak számát 3-5 között maximalizálni. Érdeemes tanulmányozni és érteni az egyes indikátorok matematikai hátterét, hogy mely értékük mit jelent. Például az oszcillátorok alacsony értékeit általánosságban vételi, míg a magas értékeket eladási pontént azonosítják.

Továbbá az indikátorok paramétereinek értéktartományát is meg kell határozni.

### 2.2.3. Be- és kilépési feltételek

Az előzőekben kiválasztott indikátorokra ki kell dolgoznunk egy matematikai vagy logikai feltételt, mely összekapcsolja őket – ez az egyenlet lesz belépési feltételünk. A rendszerépítés szépségét adja, hogy hasonlóan az adathalmaz szerkezetének meghatározásához, a belépési feltétel is igen változatos lehet (Bacidore, 2020). Az indikátorok között létrehozhatunk logikai kapcsolatot, vagy természetesen matematikai operátorokat is használhatunk.

- Példa logikai kapcsolatra:  
 $[\text{Indikátor1}(\text{paraméter1}) < \text{érték1} \ \& \ \text{Indikátor2}(\text{paraméter2}) < \text{értéke2}] = \text{igaz/hamis}$
- Példa matematikai operátorra:  
 $[\text{Indikátor1}(\text{paraméter1}) + \text{Indikátor2}(\text{paraméter2})] = \text{érték}$

Több indikátor esetén célszerű normalizálni az értékeiket, hiszen így a belépési feltételben minden indikátor ugyanazzal az értéktartománnyal fog szerepelni (Kissell, 2020). A normalizálással kiegyenlítjük az indikátorok matematikai sokszínűségéből adódó különbségeket és amennyiben ezek után favorizálni szeretnénk valamelyiket lehetőségünk van az indikátorok súlyozására (Kissell, 2020).

Majd meghatározzuk a kilépési feltételeket, melyek szintén alapulhatnak az indikátorok meghatározott értékein (pl. oszcillátorok magas értékei) vagy akár egyéb független értéken is. Ez lehet egy cél-ár vagy maximális veszteség meghatározása, de lehet akár időbeli korlát is és természetesen lehet az előbbieket kombinációja is (Bacidore, 2020).

Tulajdonképpen a belépési és kilépési feltételek nem más, mint a stratégiánk, amelyet aztán az adatfolyamon szimulálunk.


#### **2.2.4. Tanulási, tesztelési, validálási periódusok**

Borch (2022) szerint a rendelkezésre álló adathalmazunkat célszerű legalább két részre osztani. Az első részben - tanulási fázis - tanítjuk fel a modellt. Az indikátorok adott paramétereire kiszámítjuk a belépési és kilépési feltételünket minden egyes időintervallumra. Lesznek olyan időszakok, amelyeknél a belépési feltételünk teljesülni fog, ebben az esetben pozíciót létesítünk, hasonlóan, ha a kilépési feltétel válik igazgá, akkor a pozíciót zárjuk. Ezt folytatjuk az utolsó intervallumig, utána megkapjuk az ügyletek listáját a tanulási periódusban (Borch, 2022). A folyamatot addig ismétljük, amíg az összes indikátor paraméter értékét végig nem vettük, majd az így kapott egyedi rendszereket a fitness kritérium alapján sorba állítjuk (Macedo és mtsai., 2020). Kiválasztjuk azokat, melyek megfelelnek a fitness kritériumoknak és ezeket a rendszereket szimuláljuk a tesztelési perióduson. A tesztelési periódusban lévő adatok a rendszer számára teljesen ismeretlenek, így az élő kereskedést tudjuk szimulálni, és megnézhetjük, hogy a tanulási periódusban kiválasztott rendszerek milyen teljesítményt nyújtanak ezen az adathalmazon (Chung & Shin, 2020). Kiszámítjuk a fitness kritériumokat a tesztelési periódusra is minden rendszer esetén. Optimális esetben a tesztelési fázis eredményei csak kismértékben térnek el a tanulási fázisban kapott eredményektől (Chung & Shin, 2020). Amennyiben a fitness paraméterek összeomlanak a tesztelési periódusban, akkor a rendszerünk nem volt elég robusztus, így ezeket a rendszereket nincs is értelme tovább vizsgálni (Bacidore, 2020).

A tanulási és tesztelési periódusokat többféleképpen lehet meghatározni (22. ábra). A legegyszerűbb, ha az adathalmaz első részre tanulási, a második pedig a tesztelési periódus. Ennek hátránya, hogy hosszú idő alatt a pénzügyi eszköz árfolyam karakterisztikája változik, például megnő az árfolyam, változik a volatilitás és a kereskedési volumen. Ezen tényezők mind

befolyással lehetnek az eredményekre. Amennyiben a tanulási időszakban alacsony volt a volatilitás és ez alapján választottuk ki a legmagasabb fitness kritériummal rendelkező rendszereket, nem biztos, hogy egy nagy volatilitású tesztkörnyezetben hasonló eredményeket fogunk kapni a szimuláció során (Bacidore, 2020).

Azt gondolom előnyös lehet, ha a kereskedés alapjául olyan pénzügyi eszközt választunk, melynek több tíz éves árfolyamadata áll rendelkezésre és a tanulási időszakot lényegesen nagyobbra választjuk, mint a tesztelésit (pl. 70/30%). Ezzel feltételezésem szerint garantáljuk azt, hogy a rendszerünk a betanítás során a lehető legtöbb féle árfolyamkarakterisztikával találkozott, így nagyobb valószínűséggel fog megfelelő eredményeket produkálni a tesztelés során is.



22. ábra: Tanulási-tesztelési intervallumok lehetséges meghatározási módjai

*Forrás: Genetic System Builder, saját szerkesztés*

Előnyös lehet az a módszer is, ha az adathalmazt sok részre osztjuk, a tesztelési és tanulási időszakokat közel azonosan, de váltakozva határozzuk meg (22. ábra). A módszer előnye, hogy a rendszer betanításához a legutóbbi árfolyamot is felhasználjuk, és ezeknek az adatoknak a karakterisztikája van a legközelebb a valós idejű adatokhoz, illetve a tesztelési periódus a lehető legtöbb féle árfolyam karakterisztikát tartalmazza (Chung & Shin, 2020).

### 2.2.5. Genetikus algoritmusok használata, jelentősége

Ez a lépés a rendszerépítés legbonyolultabb és talán legkritikusabb folyamata, hiszen az előzőleg megtett beállítások között meg kell találni azokat a rendszereket, melyek megfelelő teljesítményt nyújtottak a múltban és ami ennél is fontosabb a jövőben is képesek folytatni azt. Bacidore (2020) szerint a hangsúly a folytatáson van, hiszen múltbeli jellemzők és értékek alapján kell felmérnünk és kiválasztanunk azokat a stratégiákat, melyek képesek profitot realizálni hosszú távon, képesek alkalmazkodni az ismeretlenhez és a kiszámíthatatlan, soha nem ismétlődő piaci trendekhez és folyamatokhoz.

Egyszerű beállítások esetén – egy-két indikátor, limitált paraméter értéktartománnyal – amennyiben kombinációk száma 10000 alatt van használhatunk lineáris keresési algoritmusokat,

melyek minden esetet végignéznek megtalálva a globális optimumot, illetve a fitness kritérium alapján rendezik a rendszereket (Pardo, 2008).

Azonban feltételezzük, hogy a több indikátort és mélységi paraméterkészletet tartalmazó rendszerek jobb eredményeket nyújtanak. Ezeknél a rendszereknél a kombinációk száma könnyen eléri a  $10^{40}$  értéket. Ilyen mennyiségű rendszerekben a lineáris algoritmusok használata értelmetlen. Helyettük a fejlett keresési algoritmusokat használunk, melyek közös tulajdonsága, hogy nem fogják megtalálni a globális optimum megoldást, hiszen nem nézik végig egyesével az összes lehetséges esetet (Dahal és mtsai., 2023). Helyette több lokális optimumra jutunk, ezek az algoritmusok véges számban futnak és minden egyes futtatáskor különböző lokális optimumot fognak eredményül adni, ugyanakkor feltételezzük, hogy ezek az eredmények megfelelően jók és közel állnak a globális optimumhoz. Fejlett keresési algoritmusok a szimulált lehűtés, genetikus és a részecske-raj alapú optimálás (Kumar és mtsai., 2021). Ezek közül a genetikus algoritmusokkal foglalkozom a következőkben. Ezek olyan módszerek, melyek az evolúció biológiai folyamatát utánozzák, robusztusok és gyorsak (Csuta & Dobák, 2023). Az 1970-es évek elején vezették be őket, de széleskörben csak a 1990-es években terjedtek el. Fontos tulajdonságaiak, hogy az esélyeket az előnyükre fordítják, két jó stratégiából képesek egy harmadik még jobbat képezni, melyet tartalmazzák az eredeti stratégiák összes előnyét. A mutáció folyamatát használják a lokális optimumon való elakadás valószínűségének csökkentésére (Pothumsetty, 2020). Első lépésként véletlenszerűen kiválasztjuk a paraméterkészletek egy csoportját (populáció). Ezen paraméterek minden egyes kombinációja (egyed) egy lehetséges stratégiát takar. Az egyedek kezdeti csoportja szétszórva található az optimalizálási térben (Pardo, 2008). A második lépésben a nem-kizárólagos paraméterkészlet párok másolása történik a következő populációba, amely a következő generáció. Annak az esélye, hogy minden paraméterkészlet-kiválasztás másolásra kerül, arányos a saját alkalmasságával, amelyet a célfüggvény mér. Ennek az a hatása, hogy a magasabb alkalmasságú paraméterkészletek természetesen uralják az egymást követő populációkat. Ezzel szemben az alacsonyabb fitnessparaméter-készleteknél nagyobb az esély a lemaradásra. Ezt a folyamatot szelekciónak nevezik (Pardo, 2008).

A harmadik lépés a paraméterkészlet párok véletlenszerű kiválasztása, majd néhány paraméter cseréje a paraméterkészlet pár egyik részéből a másik részébe (Pardo, 2008). A folyamat során az egyik paraméterkészlet jó értékei kombinálhatók jó értékekkel vagy egy másik paraméterkészlettel, hogy jobb paraméterkészletet kapjanak. Ez akkor is így van, ha a jó értékek eredetileg két különböző paraméterkészletből származnak. A negyedik lépés az, hogy ismét véletlenszerűen válasszunk egy új paraméterkészlet-csoportot (Pardo, 2008). Ezekben a paraméterkészletekben néhány paramétert új és eltérő értékekkel helyettesítenek. Ezt

mutációnak nevezik, és azt a módot követi, hogy a szerves életben a genetikai információ nem mindig reprodukálható teljes pontossággal egyik generációról a másikra (Pardo, 2008).

Bár a mutáció szó negatív kulturális jelentést hordoz magában, hosszú távon igen hasznosnak bizonyulhat, ha nem túlzó. Más szóval, nem minden mutáció rossz, akár az életről vagy akár a genetikai optimalizálásról beszélünk (Manahov, 2018). Manahov (2018) szerint néha egy mutáció azt eredményezi, hogy egy egyén – vagy paraméterkészlet – jobban alkalmazkodik a környezetéhez – vagy piacához –, mint az azt megelőzők. Ha viszont egy paraméterkészlet-mutáció gyengén teljesít, az eredményül kapott halmaz valószínűleg nem kerül át a következő generációba. Következésképpen a mutáció használata az optimalizálási folyamat időnkénti felrázására, hogy minimalizálja a konvergenciát a helyi maximumon, több hasznot hoz, mint kárt. És mivel a legmagasabb fitnessparaméter-készleteket valószínűleg többször átmásolják a következő generációba, a legjobb megoldás is kisebb valószínűséggel vesz el egy véletlen mutáció miatt (Muravyev & Picard, 2022). Az algoritmus korábban említett 2-4 lépés megismétlésével folytatódik az egymást követő generációk számára. Minden generációban új paraméterkészlet-populációkat állítanak elő. Ez addig tart, amíg az előre meghatározott számú generációt elértük, vagy kellően jó megoldás született, vagy jelentős javulás a fitnessben a populáció egészére már nem történik.

#### **2.2.6. Fitness kritériumok**

A keresési módszerek folyamatosan elfogadják vagy elutasítják a kereskedési modelleket annak érdekében, hogy a lehető legrövidebb idő alatt megkeressék a legjobb paraméterkészletet. Ezért is nagyon fontos a lehető legjobb fitness függvény használata (Pardo, 2008). A legjobb értékelési módszer az, amely kiválasztja azt a paraméterkészletet egy kereskedési stratégiához, amely a legjobban előrevetíti a valós idejű kereskedési eredményeket.

Az indikátorok paraméterinek különböző kombinációi egy-egy egyedi rendszert jelentenek, melyeknek egyediek lesznek az ügyletei is. Ha például két indikátort használunk, melynek paraméterei 0-20 intervallumban változhatnak, akkor összesen 20\*20 lehetséges kombináció lesz, tehát 400 egyedi rendszert és ügyletlistát fogunk kapni. Az ügyletek bizonyos százaléka nyereséges lesz, a többi pedig veszteséges. Meg kell határoznunk egy fitness kritériumot, mely alapján rangsoroljuk a rendszereket (Kaufman, 2013). Ez lehet valamilyen teljesítmény jellemző (pl. nettó profit), de akár lehet a maximális veszteség is. A legáltalánosabban használt fitness kritériumok a nettó profit, a nettó profit \* átlagos ügyletenkénti nyereség, a számlán realizált hozam, és a profit görbe Pearson korrelációja. A nettó profit könnyen értelmezhető, hiszen olyan rendszert szeretnénk, amely ebből a legmagasabb értéket éri el. Ugyanakkor pusztán a nettó profit nem árul el semmit a rendszerről, esetlegesen arról, hogy ezért a nettó profitért cserébe

mekkora veszteséget szenvedtünk el a kereskedés során, vagy hogy ez a profit adott esetben egy anomália és néhány ügylet eredménye (Kaufman, 2013).

A számlán realizált hozam többet árul el, hiszen ebben az esetben a nettó nyereséget elosztjuk a maximális veszteség és a kötelező letét (margin) összegével. A profit görbe Pearson-féle korrelációja megmutatja, hogy az optimális 45 fokos egyeneshez viszonyítja milyen a profit görbénk. Ennek az optimumnak az értéke 1. Ebben az esetben a profit görbe illeszkedik a 45 fokos egyenesre. Pardo (2008) előszűrésre 0.95 feletti, végleges görbe esetén 0.98 feletti Pearson korrelációs értéket fogad el (Pardo, 2008).

Személyes kedvencem a sima profit görbe függvény, mely vizuálisan minden fontos tulajdonságot elárul az adott stratégiáról. Könnyen leolvasható róla a maximális veszteség, még ennél is fontosabb az anomáliák megléte, a múltbéli trendek és a stratégia viselkedése a különböző kereskedési fázisok alatt. Hátrányai a vizualitás, és a szubjektivitás. Nagy számú rendszert hatékonyan nem tudunk vele felmérni, a személyes preferenciánkból adódik a szubjektivitás, hogy az adott görbe mennyire tetszik a szemünknek.

A rendszereket többszintű szűrésnek is alávetethetjük több fitnessz kritérium alapján, melyeket akár különböző súllyal vehetünk számításba (Manahov, 2018).

A tanulási fázisra meghatározott teljesítményfeltételek megfelelő beállításával a szimuláció során csak olyan rendszereket kapunk eredményül, melyek nyereségesek voltak. Természetes, hogy a nem nyereséges rendszereket nincs is értelme további vizsgálatoknak alávetni. Minél szigorúbb teljesítményfeltételeket szabunk, annál kevesebb rendszert fog találni a keresési algoritmus, de természetesen ez függ attól is, hogy adott piacra mennyire könnyen építhető rendszer (Kissell, 2020). Fitnessz kritériumokat nem csak a tanulási fázisra adhatunk meg, ugyanúgy szűrőket állíthatunk be a tesztelési intervallumra is. Ezáltal csak azokat a rendszereket fogjuk eredményként megkapni, melyek mind a tanulási, mind pedig a tesztelési intervallum során megfelelő eredményeket generálnak.

Pardo (2008) szerint csak azokat a rendszereket van értelme további megfelelőségi vizsgálatoknak alávetni, melyek mind a tanulási, mind a tesztelési periódusokban legalább a megszabott teljesítménykritériumokat teljesítették. Amennyiben nem találunk ilyen rendszert, akkor változtatunk kell a valamely beállításon és a teljes folyamatot meg kell ismételni.

### **2.2.7. Eredmények tesztelése, validálása**

Amikor befejeződött a rendszerek keresése és kiválasztottuk a fitnessz kritériumok szerint legjobbnak ítélt stratégiákat meg kell bizonyosodunk arról, hogy azok meg fogják állni a helyüket az élő kereskedés során is.

Robusztus rendszereket szeretnénk kiválasztani, mely alatt nem feltétlenül a legnagyobb nyereséget értjük. Ezen rendszerek ismérvei az ügyletek és az ügyletenkénti nyereség egyenletes eloszlása, a relatív egyensúly a hosszú- és a rövidtávú haszon között, a kockázat elfogadható mértéke, az ügyletek statisztikailag releváns száma (Davey, 2014).

Ugyanakkor, hogy megbizonyosodjunk arról, hogy a stratégiánk jövőbeli adatokon is megfelelően fog működni azokat további megfelelőségi vizsgálatnak kell alávetnünk. Ezek közül a legjelentősebbek:

**A stratégia más piacon, pénzügyi eszközön való tesztelése:** Amennyiben a stratégia közel azonos eredményeket produkál több különböző pénzügyi eszközön mindenképpen erős jelzés arra vonatkozóan, hogy az kellően rugalmas, alkalmazkodási képességgel rendelkezik (Pardo, 2008). Azt nem várhatjuk el, hogy maximális nettó hozamokat érjen el minden eszközön, de legalább nyereséget kell mutatnia a hasonló karakterisztikával rendelkező eszközökön. Pardo (2008) szerint ha az eredmények összeomlanak a társ-piaci tesztelés során, akkor erős a gyanú, hogy a stratégia teljesen rá van szabva az eredeti adatfolyamra és annak kismértékű jövőbeli változása nagyobb valószínűséggel lesz negatív hatással a nyereségessegre.

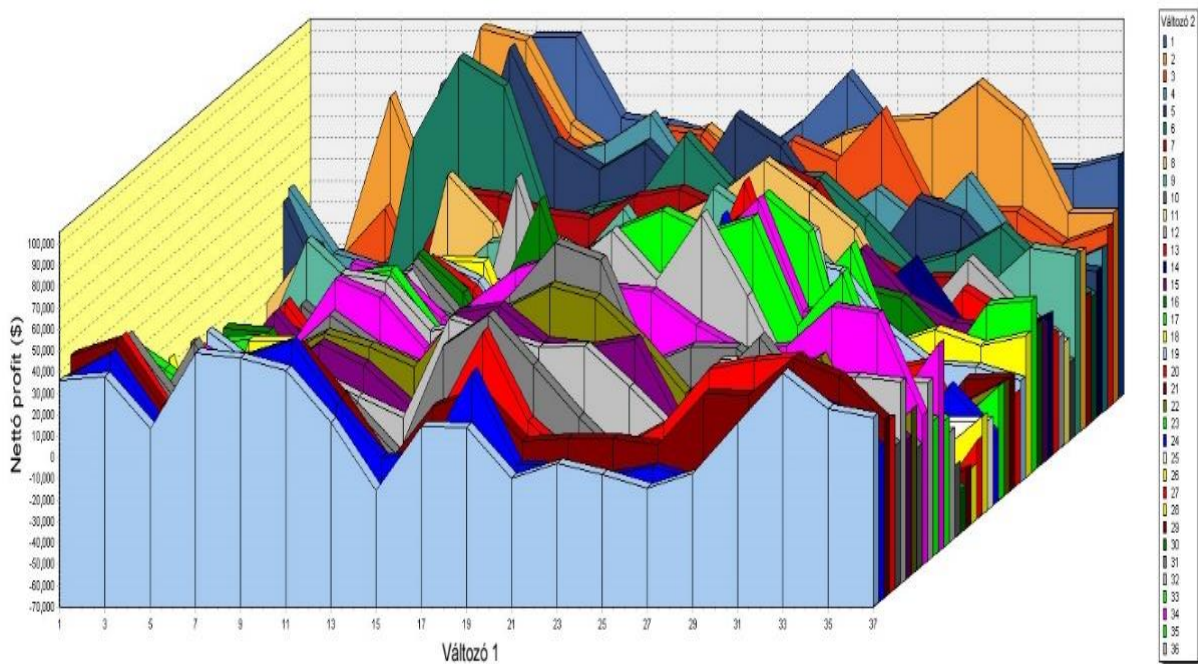
Az adatfolyam szerkezetének kismértékű változtatása során szintén arról bizonyosodunk meg, hogy a kiválasztott indikátorok és azok paraméterei megfelelően rugalmasan le tudják követni az ismeretlen adatokat (Scarpino, 2019). Scarpino (2019) szerint az adatfolyam szerkezetét két módszer szerint változtathatjuk meg:

- Random zaj hozzáadása: Ebben az esetben az árfolyam adatokat kismértékben eltorzítjuk, például a záró árakat random néhány tick értékkel módosítjuk.
- Időintervallum kismértékű változtatása: Mely esetben az eredeti időintervallumot átszabjuk, például 30 perc helyett 31 perc lesz.

Mindkét módszerrel ugyanazt érjük el, vagyis az eredeti adatszerkezet kismértékben változni fog. Amennyiben az eredmények összeomlanak az új adatszerkezeten, akkor erős a gyanú, hogy a stratégiánk nem elég robusztus és valós idejű kereskedési során csalódást fog okozni.

**Indikátorok paramétereinek kismértékű változtatása:** Egy robusztus stratégiától elvárható, hogy az indikátorok egymás melletti értékei ne okozzanak nagy változást a teljesítményben (Pardo, 2008). Például, ha az eredményeink nagymértékben változnak a mozgóátlag indikátor paraméterének 20-ról 21-re történő módosítása esetén, akkor biztosak lehetünk abban, hogy az optimalizációs tér „sziklás és csúcsos”, mely szintén negatív hatással van az eredmények folyvástagságának jövőbeli alakulására (Pardo, 2008). Szándékosan nem negatív változást írtam, hiszen előfordulhat, hogy az eredmények pozitív irányba változnak, de a stratégiáknál a legfontosabb a kiegyenlített, tervezhető teljesítmény. A 23. ábra a sziklás és csúcsos

optimalizációs teret mutat be. Ebből világosan kitűnik, hogy a változók értékeinek kismértékű módosítása is a nettó profit hektikus változásához vezet.



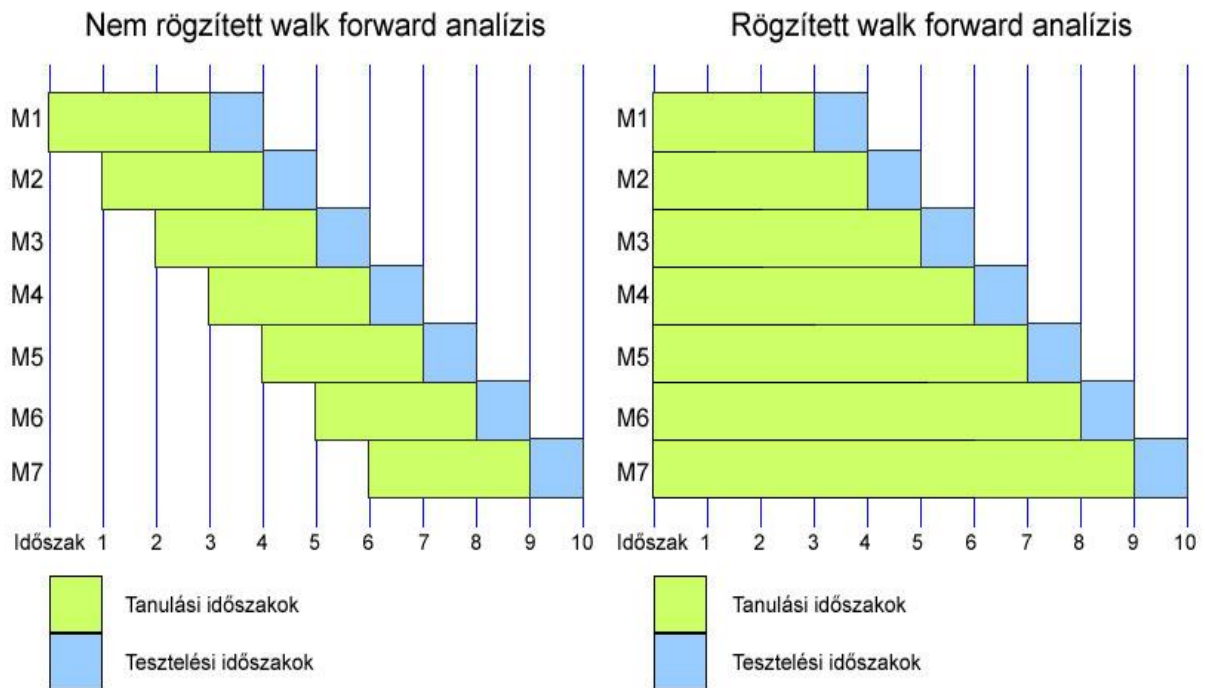
23. ábra: Sziklás és csúcsos optimalizációs tér

*Forrás: TradeStation Inc., saját szerkesztés*

**Walk forward elemzés:** Ez a módszer kizárólag a teszt időszakon való kereskedés alapján ítéli meg a rendszer robusztusságát (Davey, 2014). Ha a stratégia jól teljesít ebben az elemzésben, akkor valós eredményeket produkál, és egy lépéssel közelebb kerültünk ahhoz, hogy a stratégiát élő kereskedésben is futtassuk. A walk forward elemzés választ ad arra, hogy a piaci magatartás változásai hogyan befolyásolják a teljesítményt, továbbá, hogy milyen valós megtérülési rátával számolhatunk (Yoon, 2021).

Yoon (2021) kutatásai kimutatták, hogy az 50-60 százalékos hatékonysággal rendelkező stratégiák robusztusnak tekinthetők. Hatékonysági mutató alatt egyszerűen a mintán kívüli és a mintán belüli hozam arányát értjük. Egy rosszul felépített stratégia ez alatti hatékonyságot fog eredményül adni.





24. ábra: Walk forward analízis

*Forrás: GSB, saját szerkesztés*

A 24. ábrán hét adatkészlet áll rendelkezésünkre a betanításra és a tesztelésre. Az első halmaz végén megépítjük az M1 modellt, amelyet az első halmaz adataira tanítottunk. Ezután megismételjük a folyamatot, és felépítjük a rendszert a második halmazra és így tovább. Hét mintán kívüli időszakunk van, ezeket az eredményeket összevonnjuk és ebből készítjük el a walk forward mintán kívüli eredményeket (Pardo, 2008). A kapott eredményeket elemezve, ha minden egyes tesztidőszak teljesíti a fitness kritériumokat, akkor egy fokkal közelebb kerülünk egy olyan stratégiához, amely jövőbeli adatokon is hasonló eredményeket fog produkálni.

**Klaszterelemzés:** További bizonyosságot nyerhetünk a rendszerünk robusztusságáról klaszterelemzés segítségével, amely ez esetben nem jelent mást, mint különböző beállításokkal végzett walk-forward elemzések hatékonysági mátrixát. Tekintettel arra, hogy a walk forward elemzésénél megadhatjuk a tanulási és tesztelési időszak arányát, illetve az időszak felbontását. Így minden egyes klaszterre ki tudjuk számítani a hatékonyságot. Természetesen minél több klaszteren lesz a hatékonyság 50% fölött, annál jobb a rendszerünk.

**Paraméterstabilitás:** A modelleknek egyedi paraméter értékészletük van. A walk-forward elemzés során minden egyes tanulási időszakban optimalizáltuk a rendszerünket, így az indikátorok paraméterei is valamilyen mértékben változtak. Amennyiben adott indikátor paraméterei a különböző tesztelési időszakokban kismértékben térnek el egymástól, vagyis stabilitást mutatnak, az újabb megerősítés, hogy rendszerünk robusztus (Pardo, 2008). Hiszen a

piaci környezet és az árfolyam változása érdemben nem befolyásolta a rendszer működését, ugyanazok az indikátor értékek optimálisak voltak minden fázis során – így a jövőben is erre számíthatunk (Pardo, 2008).

**Monte Carlo elemzés:** A szimuláció végrehajtása egy valós rendszer jellemzőinek és viselkedésének megisméltéséből vagy másolásából áll (Davey, 2014). A Monte Carlo szimuláció fő célja, hogy megpróbálja utánozni a valós változók viselkedését, hogy amennyire lehetséges elemezze vagy megjósolja, hogyan fognak fejlődni. Ez egy fontos lépés, mert a véletlenszerű szimulációk drámaian eltérő nyereséget és maximális veszteséget mutathatnak (Davey, 2014). Lehetséges, hogy az ügyletek adott sorrendjében a maximális veszteség nagyon kicsi volt. De mivel a történelem nem valószínű, hogy megismétli önmagát, fontos megnézni, hogy ha az ügyleteket random összekeverjük hogyan alakulnak a veszteségek, és a profit görbe. A folyamatot többször ismételve megkapjuk a médián maximális veszteséget, hozamot, a leghosszabb veszteségben töltött időszakot, illetve ezek szórását (Davey, 2014).

**Az utolsó validációs lépés** természetesen az élő kereskedés, ahol a valós idejű piaci környezet egyéb problémáival is meg kell megbirkóznunk.

### **2.3. A rendszerépítés eszközei**

Számos szoftver létezik, mellyel a kereskedési algoritmusokat fejleszthetünk le. Ezek a szoftverek nem csak a rendszerépítés teljes folyamatát végzik el, hanem a 2.2.7. fejezetben részletezett validációs eljárások nagy részét is lefuttatják, az eredményeket rendszerezik és előkészítik, így a kvantitatív elemzőkről nagy terhet vesznek le, hiszen így az ő fő feladatuk a rendszerek kiválasztása és diverzifikált portfólióba illesztése lesz. A legnépszerűbb szoftverek körülbelül ugyanazt és ugyanúgy végzik el. Mivel egy erősen limitált piacról van szó gyakran az egyes funkciók verzióváltás követően jelennek meg a konkurencia programjában is. Pályám során több professzionális szoftvert használtam, melyeken kívül természetesen létezik számos másik is. Ebben a piaci szegmensben a legnépszerűbb szoftverek: Adaptrade Builder, StrategyQuant, Genetic System Builder (GSB). Az előbbi kettő a felhasználóbarát működésre, az erősebb marketingre, egyszerűbb átláthatóságra törekszik. Tapasztalatom szerint ezek használatához nem szükségesek mélyebb statisztikai, matematikai és programozói ismeretek, ugyanakkor az előállított rendszerek minősége sokkal alacsonyabb. Míg a Genetic System Builder (GSB) sokkal kevésbé felhasználóorientált, ugyanakkor robusztussága és képességei mérföldekkel haladják meg a másik két szoftvert. A GSB képes egyszerre több szerveren futni, azok munkáját irányítani, összehangolni és természetesen az eredményeket összegezni. Ezzel az egy tulajdonságával a rendszerépítés fizikai korlátai nagyságrendekkel kitolhatók. A beállítások

sokasága és mélysége pedig lehetőséget nyújt igazán komplex rendszerfejlesztési feladatok elvégzésére.

Ebből is adódik, hogy jelen kutatásom során a GSB 1.0.66.35. verzióját használom, melyet a feladat típusától függően erőforrásfüggő felhő alapú szerverrendszeren futtatom le. Megjegyezve azt, hogy még ebben a formában is 1-1 részfeladat futtatása napokba telik.

### 3. 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.

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

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 kifejlesztenünk. 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 árutőzsei 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 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)
- Kávé (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: A 2.1.1. és a 2.2.1. fejezetek alapján 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 a 2. táblázatban kategóriákba rendezve sorolom fel. A kategóriákat a 2.1.5. fejezetben ismertettem, illetve megtartom az ott használt színekódolást is.

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

## 2. Táblázat: Rendszerépítés indikátorai

Forrás: Genetic System Builder, saját szerkesztés

Trendkövető	Átlagos visszaállási	Momentum	Forgalom alapú	Volatilitás alapú	Szint alapú
AccumDistClose	Bollinger Lower Band	AccumDistMom	OBV	ADXR	Close
AccumDistCloseUpDn	Bollinger Upper Band	AccumDistMomClose	VWAP	ATR	CloseLessLowestLow
AccumDistDR	CCI	ADX		Chaikin Oscillator	CloseLessOpenDBpv
AccumDistDR0	DeCycler	FastK		Chaikin Oscillator Difference	CloseLessPrevCloseD
AccumSwingIndex	DeCycler Oscillator	MACD difference		ChaikinVolatility	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	RoofingFilter1Pole2	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:

[Előjel(indikátor1(paraméter1)) \* Hatvány(Abszolút érték(indikátor1(paraméter1)),0)] \*  
 [Előjel(indikátor2(paraméter2)) \* Hatvány(Abszolút érték(indikátor2(paraméter2)),0)] \*

$[El\acute{o}jel(indik\acute{a}tor3(param\acute{e}ter3)) * Hatv\acute{a}ny(Abszol\acute{u}t\ \acute{e}rt\acute{e}k(indik\acute{a}tor3(param\acute{e}ter3)),0)]$  Felfel\acute{e} keresztez 0 &  $(indik\acute{a}tor4(param\acute{e}ter4)) > X$

A d\acute{o}nt\acute{e}si felt\acute{e}tel els\acute{o} r\acute{e}sze az indik\acute{a}torok \acute{e}rt\acute{e}k\acute{e}nek el\acute{o}jel\acute{e}nek meghat\acute{a}roz\acute{a}s\acute{a}b\acute{o}l \acute{a}ll, mely negat\acute{iv} vagy pozit\acute{iv} lehet. Mivel a hatv\acute{a}nyoz\acute{a}s\acute{n}al mindig a nullad\acute{ik} hatv\acute{a}nyra emel\acute{u}nk ez\acute{e}rt a hatv\acute{a}nyoz\acute{a}s eredm\acute{e}nye 1. A hatv\acute{a}ny v\acute{a}ltoztat\acute{a}s\acute{a}val s\acute{u}lyozni lehet az indik\acute{a}torokat. Ugyanakkor \acute{e}n ett\acute{o}l eltekintek, \acute{ig}y a rendszerekn\acute{e}l minden indik\acute{a}tor\acute{o}t azonos s\acute{u}llyal vesz\acute{u}nk sz\acute{a}m\acute{it}\acute{a}sba. A „Felfel\acute{e} keresztez” formula pedig annyit tesz, hogy felt\acute{e}tel akkor \acute{ig}az, ha az eredm\acute{e}ny el\acute{o}z\acute{o} intervallumra sz\acute{a}m\acute{it}va negat\acute{iv} volt, a jelenlegi intervallumon pedig pozit\acute{iv}.

A logikai formula m\acute{a}sod\acute{ik} r\acute{e}sze pedig akkor \acute{ig}az, ha az indik\acute{a}tor \acute{e}rt\acute{e}ke egy bizonyos \acute{e}rt\acute{e}k felett van.

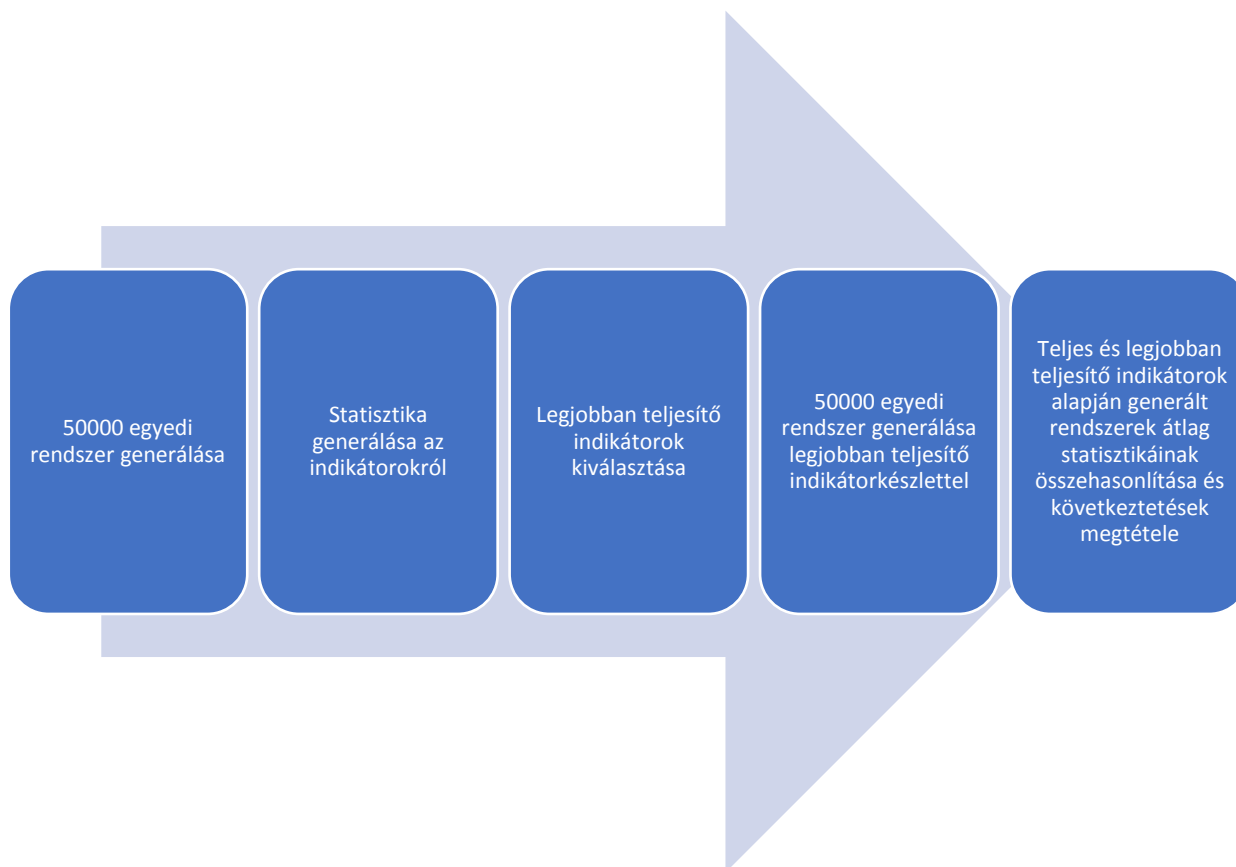
Az elad\acute{a}si poz\acute{it}\acute{o} d\acute{o}nt\acute{e}si felt\acute{e}tele a v\acute{e}teli inverze.

A d\acute{o}nt\acute{e}si felt\acute{e}telhez tartozik a keresked\acute{e}si mennyis\acute{e}g meghat\acute{a}roz\acute{a}s\acute{a}, mely minden \acute{u}gylet eset\acute{e}n 1 kontraktust jelent. Tov\acute{a}bb\acute{a}, meghat\acute{a}rozunk egy vis major kil\acute{e}p\acute{e}si felt\acute{e}tet: Az \acute{u}gyletet lez\acute{a}rjuk, amennyiben nyitott vesztes\acute{e}ge b\acute{a}rmikor meghaladja a 2000 doll\acute{a}rt.

F. Fitness krit\acute{e}riumok: Minimum krit\acute{e}riumoknak a profit faktort \acute{e}s a Pearson korrel\acute{a}ci\acute{o}t haszn\acute{a}ljuk. A teszt id\acute{o}szakban a rendszerekt\acute{o}l minim\acute{a}lisan 1,5 profit faktort \acute{e}s 0,9 korrel\acute{a}ci\acute{o}t v\acute{a}runk el. Csak azokat a rendszereket mentj\acute{u}k el tov\acute{a}bbi vizsg\acute{a}latra, melyek ezen teljes\acute{it}m\acute{e}nykrit\acute{e}riumokat teljes\acute{it}ik.

G. Optim\acute{a}lis indik\acute{a}torok meghat\acute{a}roz\acute{a}s\acute{a}: Felt\acute{e}telez\acute{e}sem, hogy egy adott piacon bizonyos indik\acute{a}torok jobb eredm\acute{e}ny\acute{u} rendszereket gener\acute{a}lnak, mint a t\acute{o}bbi indik\acute{a}tor. A 25. \acute{a}bra alapj\acute{a}n els\acute{o} l\acute{e}p\acute{e}sk\acute{e}nt gener\acute{a}lunk 50000 egyedi rendszert, melyben az \acute{o}sszes indik\acute{a}torunkat (2. t\acute{a}bl\acute{a}zat) szerepeltetj\acute{u}k.

Ezut\acute{a}n \acute{o}sszes\acute{it}j\acute{u}k az eredm\acute{e}nyeket. Felt\acute{e}telezz\acute{u}k azt, hogy ha egy indik\acute{a}tor t\acute{o}bbsz\acute{o}r fordul el\acute{o} a j\acute{o} teljes\acute{it}m\acute{e}nyt ny\acute{u}jt\acute{o} rendszerekben, mint a gyeng\acute{e}bb teljes\acute{it}m\acute{e}ny\acute{u} rendszerekben, akkor az adott indik\acute{a}tor haszn\acute{a}lat\acute{a}val jobb rendszereket lehet \acute{e}p\acute{it}eni. A gyakorlatban ezt \acute{u}gy val\acute{o}s\acute{it}juk meg, hogy fitness krit\acute{e}rium alapj\acute{a}n sorba rendezz\acute{u}k, majd a fel\acute{e}n\acute{e}l k\acute{e}t csoportra (Fels\acute{o} 50%, Als\acute{o} 50%) bontjuk a rendszereket. Ezut\acute{a}n megvizsg\acute{a}ljuk, hogy egy indik\acute{a}tor h\acute{a}nyszor fordult el\acute{o} a Fels\acute{o} 50%, illetve az Als\acute{o} 50% csoportban. A k\acute{e}t gyakoris\acute{a}gb\acute{o}l kisz\acute{a}m\acute{it}juk az el\acute{o}fordul\acute{a}si ar\acute{a}nyt. Felt\acute{e}telezz\acute{u}k, hogy jobban teljes\acute{it} az az indik\acute{a}tor, mely t\acute{o}bbsz\acute{o}r fordul el\acute{o} jobban teljes\acute{it}\acute{o} rendszerekben, tehát melynek el\acute{o}fordul\acute{a}si ar\acute{a}nya 0,5 f\acute{o}l\acute{o}tt van.



25. 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 fitness 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: A 2.2.7. fejezetben leírtak szerint 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.

### **3.2. 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 3.1. 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.

### **3.3. 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:

```
FastAvg = AverageFC( Close, 50 );  
SlowAvg = AverageFC( Close, 200 );  
if CurrentBar > 1 and FastAvg crosses over SlowAvg then  
    Buy ( !( "MA2CrossLE" ) ) 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.

## 4. EREDMÉNYEK

Dolgozatom ezen részében a 3. fejezetben ismertetett módszertan alapján fogok határidős szerződéseken rendszereket építeni és verifikálni 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 szerinti eredményeit.

### 4.1. Sovány sertés (LH) rendszerek

Sovány sertés (LH) olyan sertésre utal, amely körülbelül 200 fontot nyom és készen áll a feldolgozásra. Főként az USA Közép-Nyugati részén nevelik, és általában hat hónapba telik, mire eléri a vágósúlyt. Egy sertés körülbelül 150 font sovány húst ad, ami a sovány disznó határidős kontraktusának a magja. A határidős ügyletek 40000 font egységekben és 10,00 dolláros minimális árváltozással kereskednek. Februárban, áprilisban, májusban, júniusban, júliusban, augusztusban, októberben és decemberben jegyzik őket és készpénzben kerülnek kiegyenlítésre a lejáratkor. A piac megfelelően likvid a napon túl nyúló kereskedési stratégiák sikeres végrehajtásához. (adatok forrása: [www.cmegroup.com](http://www.cmegroup.com)). A tranzakciós költség a brókernek fizetett jutalékból és az legjobb eladási és vételi árfolyam különbségéből (elcsúszás) adódik össze: 6\$ + 20\$ ügyletenként.

#### 4.1.1. Optimális indikátorkészlet meghatározása

A 3.1. fejezetben meghatározott indikátorokat, paramétereket és egyéb változókat felhasználva meghatározzuk az optimális indikátorkészletet. Feltételezésem, hogy egy adott piacon bizonyos indikátorok jobb eredményű rendszereket generálnak, mint a többi indikátor. Első lépésként megnézem, hogy a LH határidős szerződésekre igaz e ez a hipotézis. Generálunk 50000 egyedi rendszert, melyben az összes indikátorunkat szerepeltetjük.

Ezután összesítjük az eredményeket. Feltételezzük azt, hogy ha egy indikátor többször fordul elő a jó teljesítményt nyújtó rendszerekben, mint a gyengébb teljesítésű rendszerekben akkor az adott indikátor használatával jobb rendszereket lehet építeni. A 3. táblázat azokat az indikátorokat tartalmazza, melyek előfordulási aránya 0,5 fölött van. A Felső 50% oszlopban található szám azt mutatja meg, hogy az adott indikátor hányszor fordult elő az 50% legjobban teljesítő rendszerben, míg az Alsó 50% oszlopban lévő számok az ellenkezőjét jelentik, tehát azon gyakoriságot adja meg ahányszor az 50% legrosszabbul teljesítő rendszerek részét képezte az indikátor. Az Arány oszlop pedig a kettő aránya.

3. táblázat: Indikátorok előfordulási gyakorisága sovány sertés (LH) rendszerekben

Forrás: Saját szerkesztés

Indikátor	Indikátor típusa	Felső 50%	Alsó 50%	Arány
AccumDistCloseUpDn	Trendkövető	2086	1606	0,57
AccumDistClose	Trendkövető	1916	1000	0,66
AdaptiveMovAvg	Trendkövető	494	334	0,6
BollingerUpperBand	Átlagos visszaállási	758	498	0,6
CCI	Átlagos visszaállási	824	670	0,55
CloseOverPrevHighD	Szint alapú	980	946	0,51
CloseOverPrevLowD	Szint alapú	932	384	0,71
CloseToHighLow5V4Pos	Szint alapú	774	710	0,52
CloseToHighLow6V3Neg	Szint alapú	974	834	0,54
CloseToHighLow9V2Neg	Szint alapú	966	542	0,64
DeCycler	Átlagos visszaállási	680	412	0,62
DeCyclerOscillator	Átlagos visszaállási	1018	580	0,64
Dmi	Trendkövető	2164	1362	0,61
DmiPlus	Trendkövető	724	712	0,5
FastK	Momentum	1010	592	0,63
HighLow9LessClose	Szint alapú	3132	2134	0,59
HighLowLvlNeg	Szint alapú	1562	1282	0,55
LessCloseS2R2	Szint alapú	1162	270	0,81
MyRSI	Momentum	4312	3476	0,55
SlowK	Momentum	568	384	0,6
TrendBiasExp	Trendkövető	3296	1348	0,71

Az 3. táblázatban szereplő indikátorkészlettel - a többi paramétert és változót nem módosítva – ismételten generálunk 50000 egyedi rendszert. A feltételezés szerint ezeknek a rendszereknek magasabb teljesítményt kell nyújtania. A 4. táblázat adataiból kitűnik, hogy feltevésünk helyesnek bizonyult, hiszen a módosított indikátorkészlettel épített rendszereink összesített teljesítménye jelentősen meghaladta a teljes indikátor készlettel előállított rendszerekét.

4. táblázat: Sovány sertés (LH) rendszerek átlag statisztikái

*Forrás: Genetic System Builder, saját szerkesztés*

	<b>85 indikátor</b>	<b>21 indikátor</b>	<b>Változás</b>
<b>Fitnessz</b>	3,36	4,84	44%
<b>Bruttó profit (\$)</b>	54051	59972	11%
<b>Visszahúzás (\$)</b>	-20003	-14483	-28%
<b>Ügyletenkénti nyereség (\$)</b>	160,54	212,91	33%
<b>Pearson együttható</b>	0,834	0,897	8%
<b>Profit faktor</b>	1,38	1,5	9%
<b>Ügyletszám</b>	345,42	310,43	-10%

A két módszertan alapján épített rendszerek közötti különbség egyértelmű és pozitív. Minden teljesítmény mutató erőteljes javulást mutat a módosított indikátorkészlettel épített rendszerek esetében. A feltevés igaznak bizonyult, vagyis a jobban teljesítő rendszerekben gyakrabban előforduló indikátorokkal összességében magasabb teljesítményű rendszerek építhetők. A továbbiakban ezekből választjuk ki a rendszereinket.

#### 4.1.2. Rendszerek kiválasztása, tesztelése, és verifikálása

A módosított indikátorkészlettel épített 50000 rendszerből 4 kritérium alapján 8 rendszer kiválasztása: Legnagyobb fitnessz, legmagasabb nettó profit, legnagyobb profit faktor, legnagyobb Pearson együttható.

A kiválasztott rendszerek az 5. táblázatban láthatók. Ezeket a rendszereket tartjuk a legstabilabbnak és a legesélyesebbnek arra, hogy a validáció – éles kereskedés szimulálása - során a teljesítmény mutatóik hasonló értéket fognak mutatni a tréning és teszt időszakokban tapasztaltakhoz.

5. táblázat: Kiválasztott sovány sertés (LH) rendszerek

*Forrás: Genetic System Builder, saját szerkesztés*

<b>Azonosító</b>	<b>Rendszer</b>
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(iSFDData), 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(iSFDData), 13, 100) of Data1 > 32.5
LH.20230909-154219-614805-Z8t71	((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(iSFDData), 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(iSFDData), 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(iSFDData), 13, 100) of Data1 > 50
LH.20230909-154717-342029-5YbCi	((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(iSFDData), 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(iSFDData), 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(iSFDData), 13, 100) of Data1 > 20

A kiválasztott rendszerek vegyes indikátorkészlettel és emberi szem számára random paraméterezéssel rendelkeznek. Kategóriák szerint 4 trendkövető, 2 átlagos visszaállási, 4 momentum és 8 szint alapú indikátor található. Ebből arra következtettek, hogy a sovány sertés (LH) árfolyamának karakterisztikája hosszú távon változatos, mivel nincs olyan indikátor kategória, mely arányaiban túlsúlyba kerülne a rendszerekben.

Pontosan ez a gépi rendszerépítés lényege, hogy olyan indikátor- és paraméterkombinációkat találjanak meg, melyek a hagyományos stratégiafejlesztés számára régebben lehetetlennek bizonyultak (Kühl és mtsai., 2022).

6. táblázat: Sovány sertés (LH) rendszerek WF elemzés és verifikálás eredménye

*Forrás: Genetic System Builder, saját szerkesztés*

<b>Azonosító</b>	<b>Fitnessz</b>	<b>Bruttó Profit (\$)</b>	<b>Tranzakciós költség (\$)</b>	<b>Nettó profit (\$)</b>	<b>Visszahúzás (\$)</b>	<b>Ügyletenkénti profit (\$)</b>	<b>Nyertes arány (%)</b>	<b>Pearson mutató</b>	<b>Profit faktor</b>	<b>Verifikációs arány</b>	<b>WF egyűthető (%)</b>
LH.20230909-151352-585540-7cTi4	18,42	123016	8086	114930	-6240	369,55	49,84	0,995	2,06	4/4	52,9
LH.20230909-153133-651956-hFY41	21,32	118594	4524	114070	-5350	655,57	51,72	0,989	2,74	3/4	81,61
LH.20230909-154219-614805-Z8t71	29,71	134712	5772	128940	-4340	580,81	51,8	0,995	2,63	4/4	62,12
LH.20230909-154304-998445-BVp3v	25,9	127014	5564	121450	-4690	567,52	51,87	0,995	2,55	4/4	57,79
LH.20230909-154651-313421-Uctor	25,94	144516	4966	139550	-5380	730,63	55,5	0,987	2,87	4/4	97,16
LH.20230909-154717-342029-5YbCi	24,32	142178	5018	137160	-5640	710,67	54,92	0,985	2,78	4/4	81,39
LH.20230909-163551-960930-aGEIh	18,88	147098	6448	140650	-7450	567,14	52,82	0,992	2,63	3/4	58,65
LH.20230909-163602-983301-NzJxo	16,86	145990	6890	139100	-8250	524,91	54,34	0,992	2,52	3/4	61,11

A kiválasztott rendszerek WF analízisét és 4 adatfolyamon történt verifikálását a 6. táblázat mutatja. A fenti eredményekből látszik, hogy mind a nyolc rendszer teljesíti a követelményeket,

mert a WF hatékonysági mutató és a különböző adatfolyamokon történt szimulálás eredménye minden esetben 50% fölött van.

#### 4.1.3. LH rendszerek validálása

Ebben a fejezetben a kiválasztott rendszereket a validációs adatfolyamon teszteljük. Ez az időszak a rendszerépítés során rejtett volt, a rendszerek ezekkel az adatokkal eddig nem találkoztak, így tulajdonképpen élő kereskedés szimulációjának minősül.

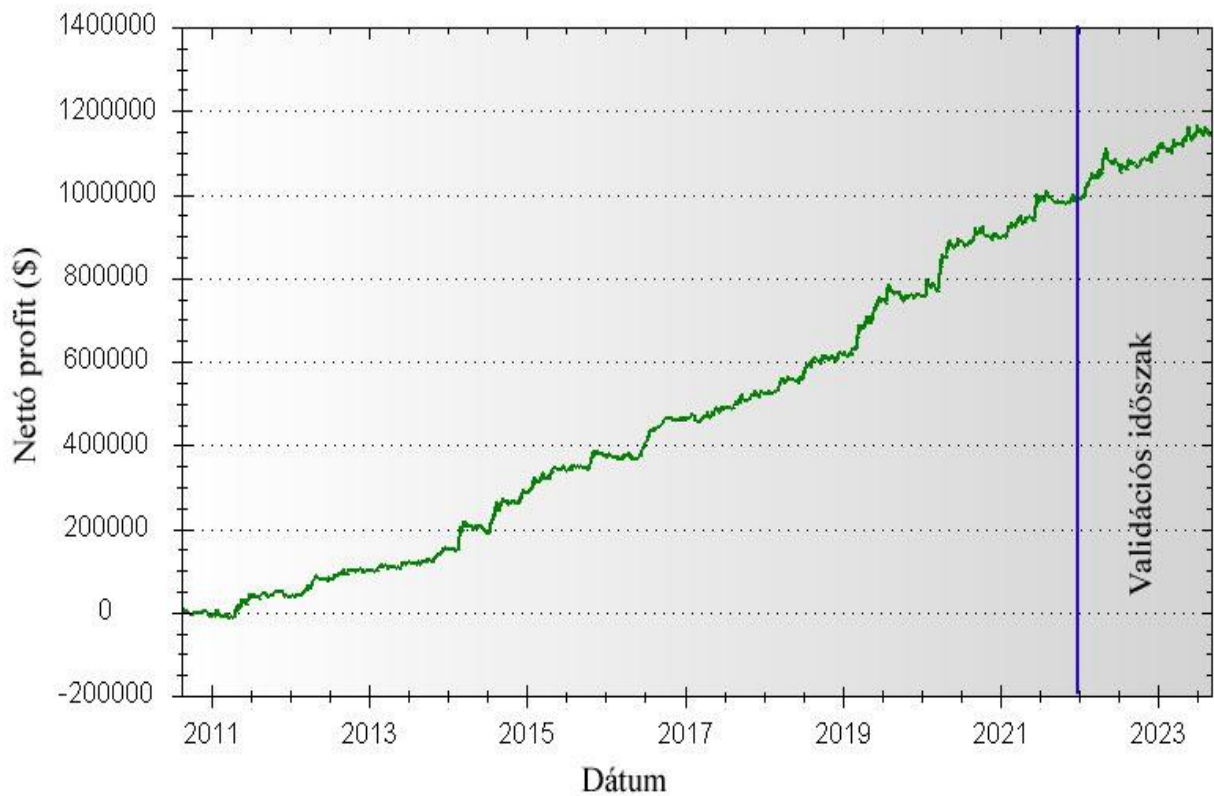
7. táblázat: Sovány sertés (LH) rendszerek validációs eredményei

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

Rendszer	Tréning és Teszt időszak		Validációs időszak	
	Nettó profit (\$)	Pearson mutató	Nettó profit (\$)	Pearson mutató
LH.20230909-151352-585540-7cTi4	114930	0,995	15895	0,899
LH.20230909-153133-651956-hFY41	114070	0,989	23710	0,935
LH.20230909-154219-614805-Z8t7l	128940	0,995	20625	0,959
LH.20230909-154304-998445-BVp3v	121450	0,995	20875	0,951
LH.20230909-154651-313421-Uctor	139550	0,987	18470	0,955
LH.20230909-154717-342029-5YbCi	137160	0,985	18350	0,953
LH.20230909-163551-960930-aGEIh	140650	0,992	6470	0,22
LH.20230909-163602-983301-NzJxo	139100	0,992	355	-0,148
<b>Összes rendszer:</b>	<b>1035850</b>	<b>0,996</b>	<b>124750</b>	<b>0,962</b>

A 7. táblázatból kitűnik, hogy a kiválasztott rendszerek megállták a helyüket a validációs időszakban. Egyetlen rendszer eredménye nullszaldós, míg a többi rendszer az elvárt profitot realizálta. Az alábbi 26. ábrán az összesített profit görbe a validációs időszakban folytatódik. Tehát összességében elmondhatjuk, hogy a rendszerépítés az LH határidős szerződésen sikeres volt.





26. ábra: LH rendszerek összesített profit görbéje

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

A diverzifikáció elengedhetetlen feltétele a sikeres hosszútávú kereskedésnek (Fry-McKibbin & McKinnon, 2023). Ugyanakkor egymással erős korrelációban álló rendszereket nincs értelme beválasztani a portfólióba, mivel azok egymást nem fogják erősíteni. A 8. táblázat a 8 kiválasztott LC rendszerünk havi teljesítményének korrelációs mátrixát mutatja be.

A 2-2 rendszer esetén a korreláció nagyon erős, ennek oka, hogy ezen rendszerek esetén az indikátorok és a paraméterek nagy átfedést mutatnak. Ezért az összesített portfólióba ezen rendszerekből csak egy-egy kerül majd bele.

8. táblázat: LH rendszerek korrelációs mátrixa

Forrás: Portfolio Analyst Pro, saját szerkesztés

	LH.20230909-151352-585540-7cTi4	LH.20230909-153133-651956-hFY41	LH.20230909-154219-614805-Z8t71	LH.20230909-154304-998445-BVp3v	LH.20230909-154651-313421-Uctor	LH.20230909-154717-342029-5YbCi	LH.20230909-163551-960930-aGEIh	LH.20230909-163602-983301-NzJxo
LH.20230909-151352-585540-7cTi4	1							
LH.20230909-153133-651956-hFY41	0,21	1						
LH.20230909-154219-614805-Z8t71	0,25	0,06	1					
LH.20230909-154304-998445-BVp3v	0,26	0,07	0,96	1				
LH.20230909-154651-313421-Uctor	0,12	0,02	0,14	0,13	1			
LH.20230909-154717-342029-5YbCi	0,17	0,03	0,12	0,11	0,99	1		
LH.20230909-163551-960930-aGEIh	0,07	0,07	0,13	0,14	0,19	0,17	1	
LH.20230909-163602-983301-NzJxo	0,00	-0,10	0,01	0,02	0,10	0,08	0,11	1

#### 4.2. Búza (W) határidős rendszerek

A búza vadon termő fű volt, mielőtt az emberek elkezdték volna termesztetni nagyobb léptékű élelmiszertermelés céljából. A régészeti kutatások azt mutatják, hogy a búzát a Nílus völgyében kezdték el termesztetni Kr.e. 5000 körül. A búza nem őshonos az Egyesült Államokban, és először 1602-ben termesztették itt, Massachusetts partjainál. Az őszi búza az Egyesült Államok teljes termelésének közel háromnegyedét adja. Főként emberi fogyasztásra használják, és a világ lakosságának élelmiszer-kalóriájának körülbelül 20%-át adja. A búza elsődleges felhasználási területe a liszt, de egyéb termékek készítéséhez is használják. A határidős szerződések 5000 vékás egységekben kerülnek meghatározásra, a minimális árváltozás pedig 12,5\$. Márciusban, májusban, júliusban, szeptemberben és decemberben jegyzik őket és a szerződések ténylegesen teljesíthetők lejáratkor (adatok forrása: [www.cmegroup.com](http://www.cmegroup.com)). A tranzakciós költség a brókernek

fizetett jutalékból és az legjobb eladási és vételi árfolyam különbségéből (elcsúszás) adódik össze: 6\$ + 25\$ ügyletenként.

#### 4.2.1. Optimális indikátorkészlet meghatározása

Generálunk 50000 egyedi rendszert, melyben az összes indikátorunkat szerepeltetjük. Ezután összesítjük az eredményeket. Feltételezzük azt, hogy ha egy indikátor többször fordul elő a jó teljesítményt nyújtó rendszerekben, mint a gyengébb teljesítésű rendszerekben akkor az adott indikátor használatával jobb rendszereket lehet építeni. A 9. táblázat azokat az indikátorokat tartalmazza, melyek előfordulási aránya 0,5 fölött van.

9. táblázat: Indikátorok előfordulási gyakorisága búza (W) határidős rendszereknél

*Forrás: GSB, saját szerkesztés*

Indikátor	Indikátor típusa	Felső 50%	Alsó 50%	Arány
Close	Szint alapú	842	430	0,66
HighLowLvlNeg	Szint alapú	745	374	0,67
AccumSwingIndex	Trendkövető	688	353	0,66
CloseToHighLow6V3Neg	Szint alapú	501	349	0,59
AccumDistMomClose	Trendkövető	501	350	0,59
TrendBiasExp	Trendkövető	471	186	0,72
CloseOverLowestLow	Szint alapú	461	307	0,6
CloseLessLowestLow	Szint alapú	443	326	0,58
FastK	Momentum	427	181	0,7
DeCycler	Átlagos visszaállási	397	187	0,68
CloseToHighLow9V2Neg	Szint alapú	384	184	0,68
RSI	Momentum	353	260	0,58
AdaptiveMovAvg	Trendkövető	346	240	0,59
ROC	Volatiliás alapú	332	241	0,58
CloseToHighLow9	Szint alapú	330	313	0,51
KeltnerUpperBand	Volatiliás alapú	327	253	0,56
HighLow9LessClose	Szint alapú	315	116	0,73
KeltnerLowerBand	Volatiliás alapú	306	262	0,54
CloseToHighLow5V4Pos	Szint alapú	293	196	0,6
Dmi	Trendkövető	273	110	0,71
XAverage	Trendkövető	258	211	0,55
AverageFc	Trendkövető	257	230	0,53
ChaikinVolatility	Volatiliás alapú	256	172	0,6
Momentum	Momentum	251	243	0,51
BollingerLowerBand	Átlagos visszaállási	249	170	0,59
MedianBand	Átlagos visszaállási	225	162	0,58

Összesen 26 indikátort találtam, melyekkel folytatom a rendszerépítés következő lépését, vagyis a módosított indikátorkészlettel újra generálunk 50000 egyedi rendszert.

10. táblázat: Búza (W) rendszerek átlag statisztikái

*Forrás: GSB, saját szerkesztés*

	<b>85 indikátor</b>	<b>26 indikátor</b>	<b>Változás</b>
<b>Fitnessz</b>	4,85	5,95	23%
<b>Bruttó profit (\$)</b>	62488	73344	17%
<b>Visszahúzás (\$)</b>	-14607	-13369	-8%
<b>Ügyletenkénti nyereség (\$)</b>	231	219,8	-5%
<b>Pearson együttható</b>	0,911	0,945	4%
<b>Profit faktor</b>	1,46	1,49	2%
<b>Ügyletszám</b>	296,2	404,4	37%

A 10. táblázatban a teljes és a módosított rendszerek átlag statisztikái láthatók. Ebből látszik, hogy a fitnessz és a nettó profit az elvárt mértékben javult az optimalizációs eljárás során, ugyanakkor a többi mérőszámunk kisebb javulást mutat. Összegezve azonban a búza (W) rendszereknél is igaznak bizonyul a hipotézis, miszerint a jobban teljesítő rendszerekben gyakrabban előforduló indikátorokkal magasabb teljesítményű rendszerek építhetők.

#### **4.2.3. Rendszerek kiválasztása, tesztelése, verifikálása**

A módosított indikátorkészlettel épített 50000 rendszerből 4 kritérium alapján 8 rendszer kiválasztása: Legnagyobb fitnessz, legmagasabb nettó profit, legnagyobb profit faktor, legnagyobb Pearson együttható.

A kiválasztott rendszerek a 11. táblázatban láthatók. Ezeket a rendszereket tartjuk a legstabilabbnak és a legesélyesebbnek arra, hogy a validáció – éles kereskedés szimulálása - során a teljesítmény mutatóik hasonló értéket fognak mutatni a tréning és teszt időszakokban tapasztaltakhoz.

11. táblázat: Búza (W) határidős szerződéseken kiválasztott rendszerek

Forrás: GSB, saját szerkesztés

Azonosító	Rendszer
W.20230917-064107-207882-W3iIL	((Sign(GSB_CloseOverLowestLow(44, 0) of Data1) * Power(Absvalue(GSB_CloseOverLowestLow(44, 0) of Data1), 0)) * ((Sign(GSB_BollingerBand(Close, 25, -1) of Data1) * Power(Absvalue(GSB_BollingerBand(Close, 25, -1) of Data1), 0)) * (Sign(GSB_Decycler(29) of Data1) * Power(Absvalue(GSB_Decycler(29) of Data1), 2)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFDData), 13, 100) of Data1 > 7.5
W.20230917-030909-341378-IuBu0	((Sign(GSB_CloseToHighLow5v4Pos(41) of Data1) * Power(Absvalue(GSB_CloseToHighLow5v4Pos(41) of Data1), 0)) * ((Sign(GSB_MedianBand(Close, 173, 4) of Data1) * Power(Absvalue(GSB_MedianBand(Close, 173, 4) of Data1), 0)) * (Sign(GSB_CloseToHighLow9v3(31) of Data1) * Power(Absvalue(GSB_CloseToHighLow9v3(31) of Data1), 1.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFDData), 13, 100) of Data1 > 7.5
W.20230917-063233-552177-cCBXp	((Sign(GSB_Close of Data1) * Power(Absvalue(GSB_Close of Data1), 0)) * ((Sign(GSB_TrendBiasExp(59) of Data1) * Power(Absvalue(GSB_TrendBiasExp(59) of Data1), 0)) * (Sign(GSB_CloseToHighLow9v3(9) of Data1) * Power(Absvalue(GSB_CloseToHighLow9v3(9) of Data1), 0.5)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFDData), 13, 100) of Data1 > 35
W.20230917-045755-280628-pR9Dg	((Sign(GSB_CloseToHighLow9v3(35) of Data1) * Power(Absvalue(GSB_CloseToHighLow9v3(35) of Data1), 0)) * ((Sign(GSB_CloseToHighLow9v3(124) of Data1) * Power(Absvalue(GSB_CloseToHighLow9v3(124) of Data1), 0)) * (Sign(GSB_KeltnerUpperBand(Close, 105, 2) of Data1) * Power(Absvalue(GSB_KeltnerUpperBand(Close, 105, 2) of Data1), 2)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFDData), 13, 100) of Data1 > 40
W.20230917-031034-489055-y9o5K	((Sign(GSB_CloseToHighLow5v4Pos(41) of Data1) * Power(Absvalue(GSB_CloseToHighLow5v4Pos(41) of Data1), 0)) * ((Sign(GSB_MedianBand(Close, 173, 4) of Data1) * Power(Absvalue(GSB_MedianBand(Close, 173, 4) of Data1), 0)) * (Sign(GSB_CloseToHighLow9v3(31) of Data1) * Power(Absvalue(GSB_CloseToHighLow9v3(31) of Data1), 1.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFDData), 13, 100) of Data1 > 27.5
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_KeltnerUpperband(Close, 105, 2) of Data1) * Power(Absvalue(GSB_KeltnerUpperBand(Close, 105, 2) of Data1), 2)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFDData), 13, 100) of Data1 > 22.5

W.20230917-041351-221264-q1swg	$((\text{Sign}(\text{XAverage}(\text{Close}, 23) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{XAverage}(\text{Close}, 23) \text{ of Data1}), 0)) * ((\text{Sign}(\text{GSB\_CloseLessLowestLow}(53, 1) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_CloseLessLowestLow}(53, 1) \text{ of Data1}), 0)) * (\text{Sign}(\text{GSB\_TrendBiasExp}(71) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_TrendBiasExp}(71) \text{ of Data1}), 0.75)))))) \text{Cross } 0 \ \& \ 0 \ \& \ \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 25$
W.20230917-032556-229158-vVNb3	$((\text{Sign}(\text{GSB\_KeltnerUpperBand}(\text{Close}, 9, 2.5) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_KeltnerUpperBand}(\text{Close}, 9, 2.5) \text{ of Data1}), 0)) * ((\text{Sign}(\text{GSB\_CloseToHighLow9v3}(35) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_CloseToHighLow9v3}(35) \text{ of Data1}), 0)) * (\text{Sign}(\text{XAverage}(\text{Close}, 164) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{XAverage}(\text{Close}, 164) \text{ of Data1}), 1.75)))))) \text{Cross } 0 \ \& \ 0 \ \& \ \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 0$

A rendszereket átnézve látjuk, hogy azok indikátorkészlete vegyes, kategóriák szerint 4 trendkövető, 4 átlagos visszaállási, 3 volatilitás alapú és 13 szint alapú indikátor található. A momentum típusú indikátorok hiányából arra következtettek, hogy a búza (W) árfolyamára kevésbé jellemzőek az egyirányú szélsőséges mozgások. A szint alapú indikátorok túlsúlya szintén erre enged következtetni, vagyis a különböző szintek használatával stabilan előre lehet jelezni az árfolyamot.

Haladhatunk tovább a walk-forward elemzéssel, és a 4 adatfolyamon történő verifikálással, ennek eredményeit a 12. táblázat mutatja.

Az eredményekből látszik, hogy négy rendszer teljesíti a verifikációs követelményeket, a walk-forward hatékonyság pedig csak egyetlen rendszer esetében van 50% felett. Ugyanakkor mindkét feltételt csak egy rendszer teljesítette, ezáltal a végleges portfólióba csak ez fog bekerülni.

12. táblázat: Búza (W) rendszerek WF elemzés és verifikálás eredménye

Forrás: GSB, saját szerkesztés

Azonosító	Fitnessz	Bruttó Profit (\$)	Tranzakciós költség (\$)	Nettó profit (\$)	Visszahúzás (\$)	Ügyletenkénti profit (\$)	Nyertes arány (%)	Pearson mutató	Profit faktor	Verifikációs arány	WF együttható
W.20230917-030909-341378-IuBu0	20,41	134558	10571	123987	-6075	363,6	54,84	0,965	1,89	0/4	28,66
W.20230917-031034-489055-y9o5K	20,44	134671	10509	124162	-6075	366,26	55,46	0,966	1,9	0/4	-4,74
W.20230917-032556-229158-vVNB3	11,6	123192	9517	113675	-9800	370,28	49,51	0,995	1,96	3/4	38,05
W.20230917-041351-221264-qlswg	15,99	162444	24707	137737	-8612	172,82	49,31	0,949	1,61	0/4	19,59
W.20230917-045755-280628-pR9Dg	12,18	141076	6076	135000	-11087	688,78	55,1	0,989	2,57	4/4	33,99
W.20230917-045839-115959-MAQJ4	10,42	135289	5952	129337	-12412	673,63	53,13	0,974	2,44	2/4	50,25
W.20230917-063233-552177-cCBXp	11,14	99912	7037	92875	-8337	409,14	49,34	0,994	1,86	2/4	6,55
W.20230917-064107-207882-W3iIL	14,32	167986	25699	142287	-9937	171,64	47,41	0,956	1,66	0/4	31,32

#### 4.2.3. Búza (W) rendszerek validálása

A validációs eljárás mindenképpen szükséges és érdekes eredményeket fog hozni, ugyanis jó verifikációs eredmények hiányában kételkedünk a rendszerek robusztusságában és abban, hogy élő kereskedés esetén a profit görbe folytatódni fog.

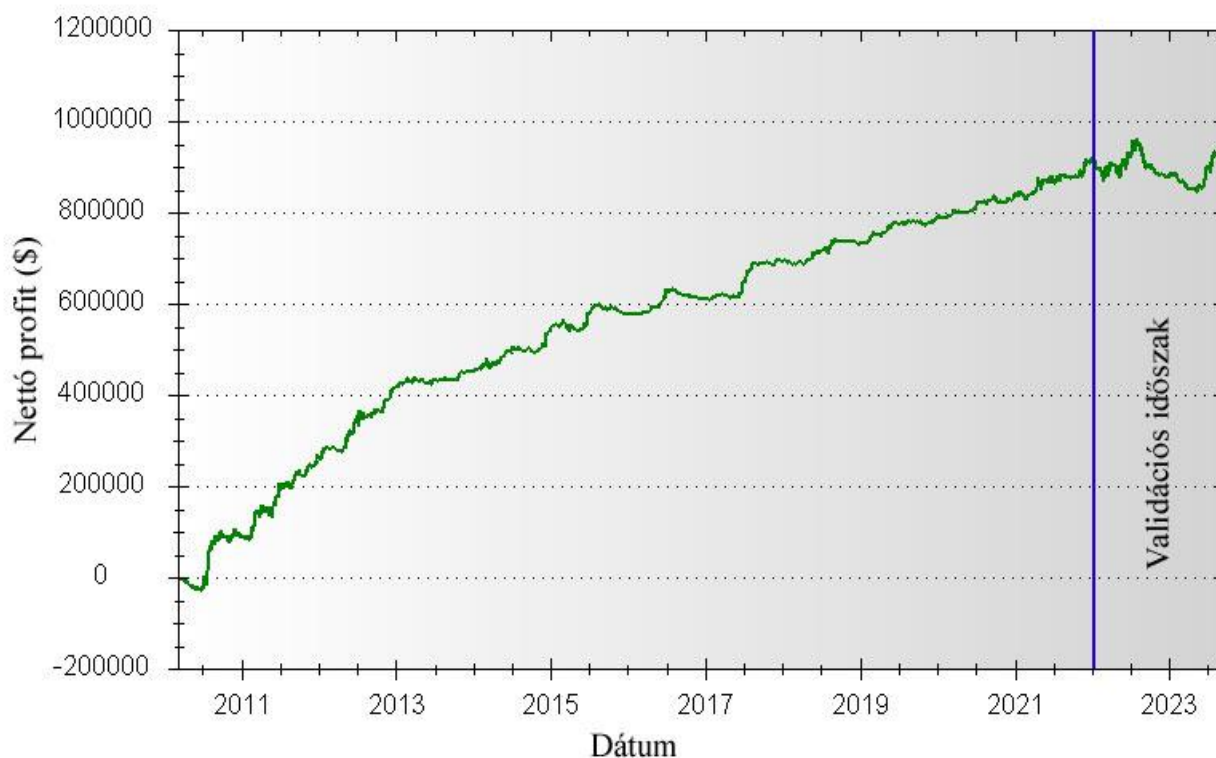
A 13. táblázatban lévő adatok alátámasztják a verifikáció során kapott gyenge eredményeket, ugyanis három rendszer tudott profitot termelni a szimulált kereskedés során, melyek közül az egyik a verifikált rendszerünk.

13. táblázat: Búza (W) rendszerek validációs eredményei

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

Rendszer	Tréning és Teszt időszak		Validációs időszak	
	Nettó profit (\$)	Pearson mutató	Nettó profit (\$)	Pearson mutató
W.20230917-030909-341378-IuBu0	123987	0,965	11630	0,632
W.20230917-031034-489055-y9o5K	124162	0,966	14320	0,642
W.20230917-032556-229158-vVNb3	113675	0,995	-3642	-0,264
W.20230917-041351-221264-qlswg	137737	0,949	-5575	-0,712
W.20230917-045755-280628-pR9Dg	135000	0,989	-7732	-0,592
W.20230917-045839-115959-MAQJ4	129337	0,974	18185	0,68
W.20230917-063233-552177-cCBXp	92875	0,994	-1885	-0,099
W.20230917-064107-207882-W3iIL	142287	0,956	-6122	-0,417
<b>Összes rendszer:</b>	999060	0,982	19179	-0,311

Ennek a három rendszernek a teljesítménye ugyanakkor ellensúlyozta a többit és a validációs időszak összességében nyereséggel zárult, mely a 27. ábrán is látható.



27. ábra: Búza (W) rendszerek összesített profit görbéje

*Forrás: Portfolio Analyst Pro, saját szerkesztés*



Kiszámítva a korrelációs mátrixot (14. táblázat) 1-1 rendszer esetén a korreláció nagyon erős, ennek oka, hogy ezen rendszerek esetén az indikátorok és a paraméterek nagy átfedést mutatnak.

14. táblázat: Búza (W) rendszerek korrelációs mátrixa

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

	LH.20230909-151352-585540-7cTi4	LH.20230909-153133-651956-hFY41	LH.20230909-154219-614805-Z8t71	LH.20230909-154304-998445-BVp3v	LH.20230909-154651-313421-Uctor	LH.20230909-154717-342029-5YbCi	LH.20230909-163551-960930-aGEIh	LH.20230909-163602-983301-NzJxo
LH.20230909-151352-585540-7cTi4	1							
LH.20230909-153133-651956-hFY41	0,21	1						
LH.20230909-154219-614805-Z8t71	0,25	0,06	1					
LH.20230909-154304-998445-BVp3v	0,26	0,07	0,96	1				
LH.20230909-154651-313421-Uctor	0,12	0,02	0,14	0,13	1			
LH.20230909-154717-342029-5YbCi	0,17	0,03	0,12	0,11	0,99	1		
LH.20230909-163551-960930-aGEIh	0,07	0,07	0,13	0,14	0,19	0,17	1	
LH.20230909-163602-983301-NzJxo	0,00	-0,10	0,01	0,02	0,10	0,08	0,11	1

Összegezve elmondható, hogy ezen módszertan alapján a Búza (W) határidős szerződéseken alacsonyabb hatékonysággal építhetők kereskedési rendszerek. Ez természetesen nem zárja ki azt, hogy a paraméterek és különös tekintettel a döntési feltétel módosításával jobb eredményeket érjünk el. Ugyanakkor céлом az, hogy kiválasszam azokat a piacokat – és rendszereket -, melyek a módszertan által biztosított keretek között a legjobb eredményeket biztosítják. Ezekből következik, hogy végleges portfólióban a búza (W) rendszerek közül mindösszesen egy fog szerepelni.

### 4.3. Kávé (KC) határidős rendszerek

A kávé a világ egyik legfontosabb áruja. A kávé egy trópusi örökzöld cserje, amely 100 láb magasra is megnőhet. Az Egyesült Államokban jelentős mennyiségű kávé Puerto Rico-n és Hawaii-on természetesen. A kávé általában kétféle babra osztják, ezek az arabica és robusta. A legszelebb körben gyártott kávé az arabica, amely a teljes termelés mintegy 70 százalékát teszi ki. Főleg 600-2000 méteres tengerszint feletti magasságban terem, a legnagyobb termelők Brazília és Kolumbia. Az arabica kávéval az Intercontinental Exchange-en (ICE) kereskednek. A robusta kávébabot alacsonyabb tengerszint feletti magasságban termesztik, a legnagyobb termelők Indonézia, Nyugat-Afrika, Brazília és Vietnam, a LIFFE tőzsdén forgalmazzák.

A világ kávékereskedelmének 90 százaléka zöld (pörköletlen) kávébabból származik. A szezonális tényezők jelentősen befolyásolják az árát. Nincs extrém csúcs a világtermelésben az év egyik szakaszában sem, bár a kávéfogyasztás a meleg nyári hónapokban több, mint 10%-kal csökken.

A határidős szerződésben foglalt kávé mennyisége 37500 font, a minimális árváltozás pedig 18,75\$. Márciusban, májusban, júliusban, szeptemberben és decemberben jegyzik a szerződéseket, melyeket fizikailag le kell szállítani az utolsó kereskedési nap után (adatok forrása: [www.ice.com](http://www.ice.com)). A tranzakciós költség a brókernek fizetett jutalékból és az legjobb eladási és vételi árfolyam különbségéből (elcsúszás) adódik össze: 6\$ + 37,5\$ ügyletenként.

#### 4.3.1. Optimális indikátorkészlet meghatározása

Generálunk 50000 egyedi rendszert, melyben az összes indikátorunkat szerepeltetjük. Ezután összesítjük az eredményeket. A 15. táblázat azokat az indikátorokat tartalmazza, melyek előfordulási aránya 0,5 fölött van.

15. táblázat: Indikátorok előfordulási gyakorisága kávé (KC) határidős szerződéseknél

*Forrás: GSB, saját szerkesztés*

Indikátor	Indikátor típusa	Felső 50%	Alsó 50%	Arány
TrueRange	Volatilitás alapú	869	646	0,57
Range	Volatilitás alapú	814	612	0,57
AccumDistMom	Momentum	696	315	0,69
AccumDistMomClose	Momentum	540	350	0,61
RSI	Momentum	385	198	0,66
StdDev	Volatilitás alapú	349	223	0,61
BollingerLowerBand	Átlagos visszaállási	335	329	0,5
ChaikinVolatility	Volatilitás alapú	284	248	0,53

Stochastic	Momentum	230	196	0,54
ATR	Volatilitás alapú	205	156	0,57
AverageFc	Trendkövető	190	156	0,55
AveMedian	Trendkövető	189	169	0,53
S3	Szint alapú	175	144	0,55
CounterTrendMedian	Trendkövető	173	167	0,51
LessCloseS2R2	Szint alapú	170	64	0,73
KeltnerUpperBand	Volatilitás alapú	168	150	0,53
HighestFc	Trendkövető	167	155	0,52
XAverage	Trendkövető	160	150	0,52
CCI	Átlagos visszaállási	158	125	0,56
CounterTrend2	Trendkövető	153	152	0,5
CounterTrend	Trendkövető	152	145	0,51

Összesen 21 indikátort találtam, melyekkel folytatom a rendszerépítés következő lépését, vagyis a módosított indikátorkészlettel újra generálunk 50000 egyedi rendszert.

16. táblázat: Kávé (KC) határidős rendszerek átlag statisztikái

*Forrás: GSB, saját szerkesztés*

	85 indikátor	21 indikátor	Változás
<b>Fitness</b>	6,28	6,91	10%
<b>Bruttó profit (\$)</b>	130485	136339	4%
<b>Visszahúzás (\$)</b>	-22343	-21331	-5%
<b>Ügyletenkénti nyereség (\$)</b>	721,9	721,64	0%
<b>Pearson együttható</b>	0,944	0,945	0%
<b>Profit faktor</b>	1,68	1,7	1%
<b>Ügyletszám</b>	208,08	216,97	4%

A 16. táblázatban a teljes és a módosított rendszerek átlag statisztikái láthatók. Ebből látszik, hogy mérőszámaink kisebb javulást mutatnak. Ez azt jelenti, hogy az optimalizált indikátorkészlettel épített rendszereink jobb összteljesítményt nyújtanak.

#### 4.3.2. Rendszerek kiválasztása, tesztelése, verifikálása

A módosított indikátorkészlettel épített 50000 rendszerből 4 kritérium alapján 8 rendszer kiválasztása: Legnagyobb fitness, legmagasabb nettó profit, legnagyobb profit faktor, legnagyobb Pearson együttható.

A kiválasztott rendszerek a 17. táblázatban láthatók. Ezeket a rendszereket tartjuk a legstabilabbnak és a legesélyesebbnek arra, hogy a validáció – éles kereskedés szimulálása - során a teljesítmény mutatóik hasonló értéket fognak mutatni a tréning és teszt időszakokban tapasztaltakhoz.

17. táblázat: Kiválasztott rendszerek kávé (KC) határidős piacokra

*Forrás: GSB, saját szerkesztés*

<b>Azonosító</b>	<b>Rendszer</b>
KC.20230919-224241-493439-KFE1M	((Sign(GSB_SS_RSI(26) of Data1) * Power(Absvalue(GSB_SS_RSI(26) of Data1), 0)) * ((Sign(GSB_HighestFC(High, 106) of Data1) * Power(Absvalue(GSB_HighestFC(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_KeltnerUpperBand(Close, 18, 3.5) of Data1) * Power(Absvalue(GSB_KeltnerUpperBand(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_AveMedianv2(Close, 114, 5) of Data1) * Power(Absvalue(GSB_AveMedianv2(Close, 114, 5) of Data1), 0)) * (Sign(GSB_HighestFC(High, 30) of Data1) * Power(Absvalue(GSB_HighestFC(High, 30) of Data1), 0.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 30
KC.20230919-233634-023218-unVvO	((Sign(GSB_AvgTrueRange(142) of Data1) * Power(Absvalue(GSB_AvgTrueRange(142) of Data1), 0)) * ((Sign(GSB_AvgTrueRange(62) of Data1) * Power(Absvalue(GSB_AvgTrueRange(62) of Data1), 0)) * (Sign(GSB_S3v2 of Data1) * Power(Absvalue(GSB_S3v2 of Data1), 1.75)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 32.5

KC.20230919-151638-852249-7bhUb	$\begin{aligned} & ((\text{Sign}(\text{GSB\_SS\_Stochastic}(18) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_SS\_Stochastic}(18) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_SS\_RSI}(42) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_SS\_RSI}(42) \\ & \text{of Data1}), 0)) * (\text{Sign}(\text{GSB\_AveMedianv2}(\text{Close}, 7, 21) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_AveMedianv2}(\text{Close}, 7, 21) \text{ of Data1}), 1)))) \text{Cross} \\ & 0 \ \& \ 0 \ \& \ \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of} \\ & \text{Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 5 \end{aligned}$
KC.20230919-233956-627799-mo4YY	$\begin{aligned} & ((\text{Sign}(\text{GSB\_AvgTrueRange}(142) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_AvgTrueRange}(142) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_AvgTrueRange}(62) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_AvgTrueRange}(62) \text{ of Data1}), 0)) * \\ & (\text{Sign}(\text{GSB\_S3v2} \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_S3v2} \text{ of Data1}), \\ & 1.5)))) \text{Cross} \ 0 \ \& \ 0 \ \& \\ & \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of Data}(\text{iSFData}), \\ & 13, 100) \text{ of Data1} > 42.5 \end{aligned}$
KC.20230919-210702-646795-NtQek	$\begin{aligned} & ((\text{Sign}(\text{GSB\_SS\_RSI}(32) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_SS\_RSI}(32) \\ & \text{of Data1}), 0)) * ((\text{Sign}(\text{GSB\_SS\_RSI}(7) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_SS\_RSI}(7) \text{ of Data1}), 0)) * \\ & (\text{Sign}(\text{GSB\_CounterTrend}(\text{Close}, 199, 4) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_CounterTrend}(\text{Close}, 199, 4) \text{ of Data1}), 1.5)))) \\ & \text{Cross} \ 0 \ \& \ 0 \ \& \ \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of} \\ & \text{Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 67.5 \end{aligned}$

A rendszereket átnézve látjuk, hogy azok indikátorkészlete változatos. Kategóriák szerint 7 trendkövető, 6 momentum, 9 volatilitás alapú és 1 szint alapú indikátor található. Ebből arra következtetek, hogy a kávé (KC) árfolyamának karakterisztikája hosszú távon trendkövető, illetve ezek a trendek hangsúlyosak és szélsőséges irányítottaságúak. A piaci szereplők hajlamosak túlreagálni híreket, illetve a spekulációs kereslet ezen a határidős piacon jelentősebb. Két rendszerben (KC.20230919-233634-023218-unVvO, KC.20230919-233956-627799-mo4YY) három indikátor megegyezik, így valószínűsíthetően közöttük erős korreláció fog fennállni.

A kiválasztott rendszerek WF analízisét és 4 adatfolyamon történt verifikálását a 18. táblázat mutatja. Az eredményekből látszik, hogy 5 rendszer teljesíti a verifikációs és hatékonysági követelményeket, így a végleges portfólióba ezek kerülnek majd bele.

18. táblázat: Kávé (KC) rendszerek WF elemzése és verifikálás eredménye

Forrás: GSB, saját szerkesztés

Azonosító	Fitnessz	Bruttó profit (\$)	Tranzakciós költség (\$)	Nettó profit (\$)	Visszahúzás (\$)	Ügyletenkénti profit (\$)	Nyertes arány (%)	Pearson mutató	Profit faktor	Verifikációs arány	WF együttható
KC.20230919-224241-493439-KFE1M	18,1	241080	16399	224681	-12413	596	45,09	0,992	1,8	3/4	83,76
KC.20230919-200905-422000-BuuXP	7,54	240663	21475	219188	-29063	444	42,71	0,954	1,61	4/4	59,12
KC.20230919-153229-046788-ZTBD5	14,29	245819	19675	226144	-15825	500	44,91	0,988	1,67	4/4	62,33
KC.20230919-233504-836152-eyBkv	10,56	179760	13447	166313	-15750	538	44,34	0,981	1,73	4/4	53,76
KC.20230919-233634-023218-unVvO	19,82	232565	10002	222563	-11231	968	46,96	0,991	2,14	1/4	99,88
KC.20230919-151638-852249-7bhUb	3,16	133966	18297	115669	-36619	275	39,9	0,79	1,33	4/4	4,8
KC.20230919-233956-627799-mo4YY	21,15	248572	8703	239869	-11344	1199	50	0,993	2,48	1/4	95,61
KC.20230919-210702-646795-NtQek	5,27	211484	24434	187050	-35475	333	44,39	0,914	1,49	4/4	77,19

### 4.3.3. Kávé (KC) rendszerek validálása


A validációs eljárás mindenképpen szükséges és érdekes eredményeket fog hozni, ugyanis az, hogy három rendszer nem teljesítette a verifikációs és walk-forward hatékonysági kritériumokat nem feltétlenül jelenti azt, hogy a szimuláció során negatív eredményeket fognak produkálni. Főként azért gondolom ezt, mert az említett rendszerek a két feltételt egyszerre nem teljesítették, ugyanakkor azokat külön vizsgálva egyikben vagy másikban jó eredményeket értek el.

A validációs eljárás (19. táblázat) nem hozott meglepetést. Az eredmények stabilok, az elvárásoknak megfelelnek még azoknál a rendszereknél is, melyek vagy a verifikáció vagy a walk-forward eljárás során gyengébben teljesítettek. Az összesített profit görbe (28. ábra) a validációs időszakban is folytatódik, így a rendszerek megállták a helyüket a szimuláció során.

19. táblázat: Kávé (KC) rendszerek validációs eredményei

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

Rendszer	Tréning és Teszt időszak		Validációs időszak	
	Nettó profit (\$)	Pearson mutató	Nettó profit (\$)	Pearson mutató
KC.20230919-151638-852249-7bhUb	115669	0,79	17104	0,826
KC.20230919-153229-046788-ZTBD5	226144	0,988	17989	0,832
KC.20230919-200905-422000-BuuXP	219188	0,954	41799	0,866
KC.20230919-210702-646795-NtQek	187050	0,914	14133	0,659
KC.20230919-224241-493439-KFE1M	224681	0,992	13082	0,695
KC.20230919-233504-836152-eyBkv	166313	0,981	8482	0,814
KC.20230919-233634-023218-unVvO	222563	0,991	31914	0,858
KC.20230919-233956-627799-mo4YY	239869	0,993	31914	0,858
<b>Összes rendszer:</b>	1601477	0,993	176417	0,919



28. ábra: Kávé (KC) rendszerek összesített profit görbéje

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

Kiszámítva a korrelációs mátrixot (20. táblázat) beigazolódott a feltevésünk, 2 rendszer (KC.20230919-233956-627799-mo4YY, KC.20230919-233634-023218-unVvO) esetén a korreláció nagyon erős, ennek oka, hogy ezen rendszerek esetén az indikátorok és a paraméterek nagy átfedést mutatnak.

20. táblázat: Kávé (KC) rendszerek korrelációs mátrixa

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

	KC.20230919-151638-852249-7bhUb	KC.20230919-153229-046788-ZTBD5	KC.20230919-200905-422000-BuuXP	KC.20230919-210702-646795-NtQek	KC.20230919-224241-493439-KFE1M	KC.20230919-233504-836152-eyBkv	KC.20230919-233634-023218-unVvO	KC.20230919-233956-627799-mo4YY
KC.20230919-151638-852249-7bhUb	1							
KC.20230919-153229-046788-ZTBD5	0,32	1						
KC.20230919-200905-422000-BuuXP	0,38	0,49	1					
KC.20230919-210702-646795-NtQek	0,38	0,41	0,29	1				
KC.20230919-224241-493439-KFE1M	0,15	0,20	0,07	0,42	1			
KC.20230919-233504-836152-eyBkv	0,14	0,14	0,03	0,30	0,28	1		
KC.20230919-233634-023218-unVvO	0,01	0,18	0,03	0,14	0,24	0,10	1	
KC.20230919-233956-627799-mo4YY	0,00	0,17	0,01	0,13	0,23	0,09	0,98	1

Összegezve elmondható, hogy a módszertan alapján a kávé (KC) határidős szerződéseken jó hatékonysággal építhetők kereskedési rendszerek. A végleges portfólióba 5 rendszer került bele, melyek teljesítették a verifikációs és walk-forward kritériumokat.



#### 4.4. Fagyasztott narancslé (OJ) határidős rendszerek

Sokaknak ismerős lehet a fagyasztott narancslé (OJ) határidős szerződés a klasszikus amerikai filmből (Szerepcsere), melyben a főszereplők sarokba szorítják a narancslé piacot. A film igaz történeten alapul és élethűen ábrázolja az akkori tőzsdei kereskedést. A fagyasztott narancslé koncentrátumot 1945-ben fejlesztették ki, aminek következtében a narancs lett az Egyesült Államok fő gyümölcsstermése. A tömegének körülbelül 50%-a gyümölcslé, a maradék héj, pép és magvak, amelyeket megszáritanak, és szarvasmarhatakarományt állítanak elő belőle. A határidős ügyletekkel és opciókkal az Intercontinental Exchange-en (ICE) kereskednek. A határidős narancslé-szerződés (OJ) 15000 font narancs szilárdanyag szállítását írja elő, jegyzése január, március, május, július, szeptember és november hónapokban történik, fizikailag leszállítandó szerződésről van szó, melynek minimális ármozgása 7,5\$ (adatok forrása: www.ice.com). A tranzakciós költség a brókernek fizetett jutalékból és az legjobb eladási és vételi árfolyam különbségéből (elcsúszás) adódik össze: 6\$ + 15\$ ügyletenként.

##### 4.4.1. Optimális indikátorkészlet meghatározása

Generálunk 50000 egyedi rendszert, melyben az összes indikátorunkat szerepeltetjük. Ezután összesítjük az eredményeket. A 21. táblázat azokat az indikátorokat tartalmazza, melyek előfordulási aránya 0,5 fölött van.

21. táblázat: Indikátorok előfordulási gyakorisága fagyasztott narancslé (OJ) határidős szerződéseknél

*Forrás: GSB, saját szerkesztés*

Indikátor	Indikátor típusa	Felső 50%	Alsó 50%	Arány
HighLow9LessClose	Szint alapú	2905	1540	0,65
CloseOverLowestLow	Szint alapú	1427	1326	0,52
CloseLessOpenDBpv	Szint alapú	1412	966	0,59
CloseLessPrevHighD	Szint alapú	1357	1117	0,55
HighLowLvlNeg	Szint alapú	1205	898	0,57
Stochastic	Momentum	1199	612	0,66
ROC	Momentum	1090	737	0,6
MyRSI	Momentum	987	769	0,56
SlowK	Momentum	925	787	0,54
Dmi	Trendkövető	922	673	0,58
DeCyclerOscillator	Átlagos visszaállási	908	717	0,56
CCI	Átlagos visszaállási	906	616	0,6
CloseOverPrevLowD	Szint alapú	863	842	0,51

DeCycler	Átlagos visszaállási	850	723	0,54
CloseOverPrevHighD	Szint alapú	841	597	0,58
ChaikinVolatility	Volatilitás alapú	814	796	0,51
RSI	Momentum	765	456	0,63
KeltnerLowerBand	Volatilitás alapú	758	587	0,56
BollingerLowerBand	Átlagos visszaállási	722	461	0,61
CloseToHighLow6V3Neg	Szint alapú	687	641	0,52
CloseToHighLow9V2Neg	Szint alapú	661	556	0,54
CloseLessPrevLowD	Szint alapú	632	518	0,55
MedianBand	Átlagos visszaállási	623	535	0,54
AverageFc	Trendkövető	570	437	0,57

Összesen 24 indikátort találtam, melyekkel folytatom a rendszerépítés következő lépését, vagyis a módosított indikátorkészlettel újra generálunk 50000 egyedi rendszert. A 22. táblázatban a teljes és a módosított rendszerek átlag statisztikái láthatók.

22. táblázat: Fagyasztott narancslé (OJ) határidős rendszerek átlag statisztikái

*Forrás: GSB, saját szerkesztés*

	85 indikátor	24 indikátor	Változás
<b>Fitness</b>	4,34	5,25	21%
<b>Bruttó profit (\$)</b>	57880	64714	12%
<b>Visszahúzás (\$)</b>	-15803	-14329	-9%
<b>Ügyletenkénti nyereség (\$)</b>	169,23	179,65	6%
<b>Pearson együttható</b>	0,807	0,849	5%
<b>Profit faktor</b>	1,53	1,58	3%
<b>Ügyletszám</b>	358,01	374,97	5%

A 22. táblázatból látszik, hogy mérőszámaink az elvárt javulást mutatják. Ez azt jelenti, hogy az optimalizált indikátorkészlettel épített rendszereink jobb összteljesítményt nyújtanak.

#### 4.4.2. Rendszerek kiválasztása, tesztelése, verifikálása

A módosított indikátorkészlettel épített 50000 rendszerből 4 kritérium alapján 8 rendszer kiválasztása: Legnagyobb fitness, legmagasabb nettó profit, legnagyobb profit faktor, legnagyobb Pearson együttható.

A kiválasztott rendszerek a 23. táblázatban láthatók. Ezeket a rendszereket tartjuk a legstabilabbnak és a legesélyesebbnek arra, hogy a validáció – éles kereskedés szimulálása -

során a teljesítmény mutatóik hasonló értéket fognak mutatni a tréning és teszt időszakokban tapasztaltakhoz.

23. táblázat: Kiválasztott rendszerek fagyasztott narancslé (OJ) határidős piacokra

*Forrás: GSB, saját szerkesztés*

Azonosító	Rendszer
OJ.20230922-045352-796815-KIvBH	$\begin{aligned} & ((\text{Sign}(\text{GSB\_ChaikinVolatilityv2}(13, 140) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_ChaikinVolatilityv2}(13, 140) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_CCI}(4) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_CCI}(4) \text{ of Data1}), \\ & 0)) * (\text{Sign}(\text{GSB\_CloseLessPrevLowDv2} \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_CloseLessPrevLowDv2} \text{ of Data1}), 0)))) \text{ Cross } 0 \ \& \\ & 0 \ \& \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of} \\ & \text{Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 7.5 \end{aligned}$
OJ.20230922-064801-932229-cRk8F	$\begin{aligned} & ((\text{Sign}(\text{GSB\_SS\_Stochastic}(71) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_SS\_Stochastic}(71) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_CCI}(22) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_CCI}(22) \text{ of} \\ & \text{Data1}), 0)) * (\text{Sign}(\text{GSB\_CloseLessPrevHighDv2} \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_CloseLessPrevHighDv2} \text{ of Data1}), 0)))) \text{ Cross } 0 \ \& \\ & 0 \ \& \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of} \\ & \text{Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 2.5 \end{aligned}$
OJ.20230922-065359-186625-D0RI0	$\begin{aligned} & ((\text{Sign}(\text{GSB\_CloseLessPrevHighDv2} \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_CloseLessPrevHighDv2} \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_CCI}(17) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_CCI}(17) \text{ of} \\ & \text{Data1}), 0)) * (\text{Sign}(\text{GSB\_HighLow9LessClose}(11) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_HighLow9LessClose}(11) \text{ of Data1}), 0)))) \text{ Cross } 0 \ \& \\ & 0 \ \& \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of} \\ & \text{Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 60 \end{aligned}$
OJ.20230922-074901-228030-Fx6aH	$\begin{aligned} & ((\text{Sign}(\text{GSB\_HighLowLvlNeg}(16) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_HighLowLvlNeg}(16) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_SS\_RSI}(106) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_SS\_RSI}(106) \text{ of Data1}), 0)) * \\ & (\text{Sign}(\text{GSB\_BollingerLowerBand}(\text{Close}, 11, -3) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_BollingerLowerBand}(\text{Close}, 11, -3) \text{ of Data1}), 0)))) \\ & \text{Cross } 0 \ \& 0 \ \& \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of} \\ & \text{Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 60 \end{aligned}$
OJ.20230922-064325-146027-RBWAc	$\begin{aligned} & ((\text{Sign}(\text{GSB\_DeCyclerOscillator}(35, 45) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_DeCyclerOscillator}(35, 45) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_HighLow9LessClose}(36) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_HighLow9LessClose}(36) \text{ of Data1}), 0)) * \\ & (\text{Sign}(\text{GSB\_DMI}(48) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_DMI}(48) \text{ of} \\ & \text{Data1}), 0)))) \text{ Cross } 0 \ \& 0 \ \& \\ & \text{GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of Data}(\text{iSFData}), \\ & 13, 100) \text{ of Data1} > 40 \end{aligned}$
OJ.20230922-064550-334839-fAonB	$\begin{aligned} & ((\text{Sign}(\text{GSB\_DeCyclerOscillator}(35, 45) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_DeCyclerOscillator}(35, 45) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_HighLow9LessClose}(36) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_HighLow9LessClose}(36) \text{ of Data1}), 0)) * \\ & (\text{Sign}(\text{GSB\_DMI}(79) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_DMI}(79) \text{ of} \\ & \text{Data1}), 0)))) \text{ Cross } 0 \ \& 0 \ \& \end{aligned}$

	GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 40
OJ.20230922-045427-522624-OtxU2	$\begin{aligned} & ((\text{Sign}(\text{GSB\_ChaikinVolatilityv2}(13, 140) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_ChaikinVolatilityv2}(13, 140) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_CCI}(4) \text{ of Data1}) * \text{Power}(\text{Absvalue}(\text{GSB\_CCI}(4) \text{ of Data1}), \\ & 0)) * (\text{Sign}(\text{GSB\_CloseLessPrevLowDv2} \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_CloseLessPrevLowDv2} \text{ of Data1}), 0)))) \text{ Cross 0 \& } \\ & 0 \& \text{ GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of } \\ & \text{Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 20 \end{aligned}$
OJ.20230922-234520-464434-4x49z	$\begin{aligned} & ((\text{Sign}(\text{GSB\_MedianBand}(\text{Close}, 43, 1) \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_MedianBand}(\text{Close}, 43, 1) \text{ of Data1}), 0)) * \\ & ((\text{Sign}(\text{GSB\_CloseOverPrevHighDv2} \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_CloseOverPrevHighDv2} \text{ of Data1}), 0)) * \\ & (\text{Sign}(\text{GSB\_CloseLessPrevLowDv2} \text{ of Data1}) * \\ & \text{Power}(\text{Absvalue}(\text{GSB\_CloseLessPrevLowDv2} \text{ of Data1}), 0)))) \text{ Cross 0 \& } \\ & 0 \& \text{ GSB\_Norm5}(\text{GSB\_CloseToHighLow3v5}(\text{iSFLength}) \text{ of } \\ & \text{Data}(\text{iSFData}), 13, 100) \text{ of Data1} > 25 \end{aligned}$

A rendszereket átnézve látjuk, hogy azok indikátorkészlete vegyes. Kategóriák szerint 1 trendkövető, 7 átlagos visszaállási, 2 momentum, 2 volatilitás alapú és 9 szint alapú indikátor található. Ebből arra következtetek, hogy a fagyasztott narancslé (OJ) árfolyamának karakterisztikája hosszú távon változatos, meghatározott szintek között mozog, mivel a kapott eredményekben túlsúlyban vannak az átlagos visszaállási és szint alapú indikátorok.

2-2 rendszerben (OJ.20230922-064325-146027-RBWAc, OJ.20230922-064550-334839-fAonB és OJ.20230922-045352-796815-KIvBH, OJ.20230922-045427-522624-OtxU2) az indikátorok megegyeznek, csak paramétereik különböznek, így valószínűsíthető, hogy közöttük erős korreláció fog fennállni.

A kiválasztott rendszerek WF analízisét és 4 adatfolyamon történt verifikálását a 24. táblázat mutatja. Az eredményekből látszik, hogy az összes rendszer teljesíti a verifikációs követelményeket, míg a walk-forward elemzésnél két rendszer bukott el. Így a végleges portfólióba hat rendszer kerül bele.

24. táblázat: Fagyasztott narancslé (OJ) rendszerek WF elemzése és verifikálás eredménye

Forrás: GSB, saját szerkesztés

Azonosító	Fitnessz	Bruttó profit (\$)	Tranzakciós költség (\$)	Nettó profit (\$)	Visszahúzás (\$)	Ügyletenkénti profit (\$)	Nyertes arány (%)	Pearson mutató	Profit faktor	Verifikációs arány	WF együttható
OJ.20230922-045352-796815-KIvBH	8,61	103161	10656	92505	-10740	156,26	48,65	0,915	1,68	2/4	58,2
OJ.20230922-064801-932229-cRk8F	6,47	88504	7902	80602	-12465	183,6	52,39	0,934	1,66	3/4	42,73
OJ.20230922-065359-186625-DORIO	7,4	99742	7560	92182	-12450	219,48	54,05	0,952	1,8	4/4	68,71
OJ.20230922-074901-228030-Fx6aH	10,1	98746	6174	92572	-9165	269,89	50,15	0,911	1,92	3/4	28,97
OJ.20230922-064325-146027-RBWAc	7,59	96802	8010	88792	-11700	199,53	50,79	0,883	1,74	3/4	55,37
OJ.20230922-064550-334839-fAonB	8,34	88131	7056	81075	-9720	206,82	51,79	0,894	1,8	3/4	64,71
OJ.20230922-045427-522624-OtxU2	9,71	105490	10368	95122	-9795	165,14	50,17	0,924	1,69	3/4	55,8
OJ.20230922-234520-464434-4x49z	8,77	87543	5148	82395	-9397	288,09	50,7	0,969	1,95	2/4	54,51

#### 4.4.3. Fagyasztott narancslé (OJ) rendszerek validálása


Két rendszer nem teljesítette a walk-forward hatékonysági kritériumokat, de ez nem feltétlenül jelenti azt, hogy az élő szimuláció során negatív eredményeket fognak produkálni. Főként azért gondolom ezt, mert az említett rendszerek verifikáció esetén jó eredményeket értek el.

A validációs eljárás (25. táblázat) eredményei stabilok, az elvárásoknak megfelelnek még azoknál a rendszereknél is, melyek vagy a verifikáció során gyengébben teljesítettek. Az összesített profit görbe (29. ábra) a validációs időszakban is folytatódik, így a rendszerek megállták a helyüket a szimuláció során.

25. táblázat: Fagyasztott narancslé (OJ) rendszerek validációs eredményei

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

Rendszer	Tréning és Teszt időszak		Validációs időszak	
	Nettó profit (\$)	Pearson mutató	Nettó profit (\$)	Pearson mutató
OJ.20230922-045352-796815-KIvBH	92505	0,915	17420	0,913
OJ.20230922-045427-522624-OtxU2	95122	0,924	16725	0,936
OJ.20230922-064325-146027-RBWAc	88792	0,883	525	0,578
OJ.20230922-064550-334839-fAonB	81075	0,894	-857	0,631
<b>OJ.20230922-064801-932229-cRk8F</b>	<b>80602</b>	<b>0,934</b>	<b>9040</b>	0,793
OJ.20230922-065359-186625-D0RI0	92182	0,952	13580	0,896
<b>OJ.20230922-074901-228030-Fx6aH</b>	<b>92572</b>	<b>0,911</b>	<b>10577</b>	0,904
OJ.20230922-234520-464434-4x49z	82395	0,969	4852	0,871
<b>Összes rendszer:</b>	<b>705245</b>	<b>0,984</b>	<b>71862</b>	<b>0,914</b>



29. ábra: Fagyasztott narancslé (OJ) rendszerek összesített profit görbéje

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

Kiszámítva a korrelációs mátrixot (26. táblázat), 2-2 rendszer (OJ.20230922-045427-522624-OtxU2, OJ.20230922-045352-796815-KIvBH és OJ.20230922-064550-334839-fAonB, OJ.20230922-064325-146027-RBWAc) esetén a korreláció nagyon erős, ennek oka, hogy ezen rendszerek esetén az indikátorok és a paraméterek nagy átfedést mutatnak.

26. táblázat: Fagyasztott narancslé (OJ) rendszerek korrelációs mátrixa

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

	OJ.20230922-045352-796815-KIvBH	OJ.20230922-045427-522624-OtxU2	OJ.20230922-064325-146027-RBWAc	OJ.20230922-064550-334839-fAonB	OJ.20230922-064801-932229-cRk8F	OJ.20230922-065359-186625-D0RI0	OJ.20230922-074901-228030-Fx6aH	OJ.20230922-234520-464434-4x49z
OJ.20230922-045352-796815-KIvBH	1							
OJ.20230922-045427-522624-OtxU2	0,97	1						
OJ.20230922-064325-146027-RBWAc	0,30	0,27	1					
OJ.20230922-064550-334839-fAonB	0,20	0,19	0,82	1				
OJ.20230922-064801-932229-cRk8F	0,14	0,15	0,27	0,22	1			
OJ.20230922-065359-186625-D0RI0	0,27	0,26	0,25	0,22	0,16	1		
OJ.20230922-074901-228030-Fx6aH	-0,03	-0,05	0,18	0,11	0,11	0,17	1	
OJ.20230922-234520-464434-4x49z	0,39	0,37	0,26	0,23	0,16	0,20	0,07	1

Összegezve elmondható, hogy a módszertan alapján a fagyasztott narancslé (OJ) határidős szerződéseken jó hatékonysággal építhetők kereskedési rendszerek. A végleges portfólióba 6 rendszer került bele, melyek teljesítették a verifikációs és walk-forward kritériumokat.

## 4.5. A gépi modellépítés portfólió szintű eredményei

Összesítve a 4.1.-4.4. pontokat elkészítjük a végleges portfóliót, mely összesen 20 rendszerből áll (8 LH, 1 W, 5 KC, 6 OJ). A feladatunk, hogy az előzőkben kapott validációs eredményeket összefűzzük, kiszámoljuk a portfólió szintű eredményeket, azokból levonjuk a megfelelő következtetéseket.

27. táblázat: A portfólió összesített eredményei


*Forrás: Portfolio Analyst Pro, saját szerkesztés*

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

A 27. 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 módszerivel 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 2.1.8. fejezetben ismertetett 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 30. 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.





30. ábra: A portfólió összesített profit görbéje

*Forrás: Portfolio Analyst Pro, saját szerkesztés*

#### 4.6. A tradicionális modell 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 31. ábra mutatja.



31. 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 28. 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.

28. 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

#### 4.7. Egyszerű kereskedési modell eredményei

A 3.3 fejezetben ismertetett mozgóátlag keresztezés stratégiát EasyLanguage és TradeStation kereskedési platform segítségével futtatom le. Piacenként 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.


A 29. táblázat az egyszerű modell által elért eredményeket mutatja. Látható, hogy a stratégia nem tudott profitot termelni a validációs időszakban.

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



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

*Forrás: Portfolio Analyst Pro*

#### 4.8. Kutatási hipotézisek igazolása

Doktori értekezésem eredményeire és az ahhoz kapcsolódó vizsgálataimra támaszkodva az alábbiak szerint értékelem a dolgozat bevezetésében megfogalmazott hipotéziseket.

*1A. hipotézis (H1): A tradicionális befektetési modell – megvesz és tart – alkalmazásával sikeresebben lehet kereskedni a határidős piacokon, mint egy felépített kereskedési algoritmus alkalmazásával.*

Kutatásom során bebizonyosodott, hogy a gépi modellépítés valid kereskedési rendszereket eredményez, melyek megállják a helyüket számukra ismeretlen árfolyam adatokon való kereskedés során. A gépi modellépítés lépései:

- A piacok meghatározása: Kiválasztjuk azokat az eszközöket, melyeken a rendszereket meg szeretnénk építeni.
- Portfólió definiálása: Előre eldöntjük hogyan épül fel, hány rendszert tartalmaz.
- Adatbázis meghatározása: Ez jelenti az adatok összességét, illetve az adatszerkezet definiálását is.

- Indikátorok és azok paraméterei: Kiválasztjuk, hogy a rendszerépítéshez, mely technikai indikátorokat fogjuk felhasználni és megadjuk azok paramétereinek leírását.
- Döntési feltétel megalkotása: Matematikai és logikai műveletekkel felállítjuk azt az egyenletet, melyet az adatokon lefuttatva megadja az egyes rendszereket és az ahhoz tartozó ügyletek listáját.
- Optimális indikátorkészlet meghatározása: Adott piacon bizonyos indikátorok jobb eredményű rendszereket generálnak, mint a többi indikátor, ezért a modellépítés részeként szükséges először az optimális indikátorkészlet meghatározására.
- Fitnessz kritériumok: A döntési feltétel lefuttatása az adathalmazra sok millió egyedi rendszert eredményez. Ezek közül azokat a rendszereket szűrjük ki, melyek teljesítik a fitnessz kritériumokat.
- Rendszerek kiválasztása: Az optimális indikátorkészlet alapján generált rendszerből Pearson korreláció, legmagasabb nettó profit, legnagyobb profit faktor, illetve legmagasabb fitnessz kritérium alapján kiválasztjuk a legjobb rendszereket.
- Kiválasztott rendszerek verifikálása és walk-forward elemzése: Megbizonyosodunk arról, hogy a kiválasztott rendszerek megfelelő teljesítményt nyújtanak módosított adathalmazon is.
- Portfólió validálása: Ellenőrizzük, hogy a kiválasztott rendszerek számukra ismeretlen árfolyam adatokon is megfelelő teljesítmény biztosítanak.

Az előzőekben ismertetett gépi algoritmikus modell a tradicionális befektetési modellhez képest lényegesen nagyobb és stabilabb nettó nyereséget termelt a validációs időszakban.

**Ezért a H1A hipotézist elvetem.**

*1B. hipotézis (H1B): A gépi modell által alkotott algoritmusokkal nyereségesebben lehet kereskedni, mint egy egyszerű, általánosan ismert stratégiával (mozgóátlag keresztezés).*

Kutatásom során bebizonyosodott, hogy a gépi modellépítés kereskedési rendszerei stabil és konzisztens nyereséget termeltek, ellentétben az egyszerű kereskedési stratégia (mozgóátlag keresztezés) által generált veszteséggel (30. táblázat).

30. táblázat: Gépi modell és egyszerű stratégia eredményei

Forrás: Saját szerkesztés

	Gépi modell nettó profit (\$)	Egyszerű stratégia Nettó profit (\$)
Sovány sertés (LH)	124750	-119000
Búza (W)	18185	7042
Kávé (KC)	95485	47281
Fagyasztott narancslé (OJ)	52247	-64065
Összesen	290667	-128742

Ezért a H1B hipotézist igazoltnak tekintem.

2A. hipotézis (H2A): Meghatározható egy olyan indikátor- és paraméterkészlet, ami alapján a számítógép vezérelt algoritmikus modell hosszú távon sikeresen tud kereskedni.

A gépi modellépítés során négy határidős piacon többszázezer rendszert építettem. Ebből egy egyszerű módszertan alapján 32 rendszert választottam ki, melyek közül 20 rendszert sikeresen teszteltem és verifikáltam (31. táblázat).

31. 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-Z8t71	((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.20230909-154717-342029-5YbCi	((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 > 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_KeltnerUpperBand(Close, 105, 2) of Data1) * Power(Absvalue(GSB_KeltnerUpperBand(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-DORI0	((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)) * (Sign(GSB_HighLow9LessClose(11) of Data1) * Power(Absvalue(GSB_HighLow9LessClose(11) of Data1), 0)))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 60
OJ.20230922-064325-	((Sign(GSB_DeCyclerOscillator(35, 45) of Data1) * Power(Absvalue(GSB_DeCyclerOscillator(35, 45) of Data1), 0)) * ((Sign(GSB_HighLow9LessClose(36) of Data1) *

146027-RBWAc	Power(Absvalue(GSB_HighLow9LessClose(36) of Data1), 0) * (Sign(GSB_DMI(48) of Data1) * Power(Absvalue(GSB_DMI(48) of Data1), 0))) Cross 0 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 40
OJ.20230922-064550-334839-fAonB	((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 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 40
OJ.20230922-045427-522624-OtxU2	((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 > 20
OJ.20230922-234520-464434-4x49z	((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 & 0 & GSB_Norm5(GSB_CloseToHighLow3v5(iSFLength) of Data(iSFData), 13, 100) of Data1 > 25

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.

**Ezért a H2A hipotézist igazoltnak tekintem.**

*2B. hipotézis (H2B): Bizonyítható, hogy az adott piacon jobban teljesítő indikátorokon alapuló rendszerek összesített teljesítménye nagyobb lesz, mint az összes indikátor segítségével generált rendszerek összesített teljesítménye.*

Kutatásom során négy határidős piacot vizsgáltam meg. A 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 javulás mértékét a 32. táblázatban foglalom össze.

32. táblázat: Optimális indikátorkészlettel épített rendszerek mérőszámainak változása

*Forrás: Saját szerkesztés*

	LH rendszerek (%)	W rendszerek (%)	KC rendszerek (%)	OJ rendszerek (%)
<b>Fitnesz</b>	44	23	23	21
<b>Nettó profit</b>	11	17	17	12
<b>Visszahúzás</b>	-28	-8	-8	-9
<b>Ügyletenkénti nyereség</b>	33	-5	-5	6
<b>Pearson együttható</b>	8	4	4	5
<b>Profit faktor</b>	9	2	2	3
<b>Ügyletszám</b>	-10	37	37	5

**Ezért a H2B hipotézisem igazoltnak tekintem.**

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

Kutatásom során minden rendszerre kiszámítottam a Pearson korrelációs együtthatót, mely megmutatja, hogy a profit görbe hogyan illeszkedik a 45 fokos meredekségű egyenesre. A hipotézis igazolást nyert, ugyanis az egyes rendszerek Pearson együtthatója alacsonyabb volt, mint a teljes portfólió Pearson együtthatója akár a tréning és teszt időszakot, akár a validációs időszakot vizsgáljuk (33. táblázat).

33. táblázat: Rendszerek és teljes portfólió korrelációs együtthatói

Forrás: Saját szerkesztés

Rendszer	Tréning és Teszt időszak Pearson mutató	Validációs időszak Pearson mutató
LH.20230909-151352-585540-7cTi4	0,995	0,899
LH.20230909-153133-651956-hFY41	0,989	0,935
LH.20230909-154219-614805-Z8t7l	0,995	0,959
LH.20230909-154304-998445-BVp3v	0,995	0,951
LH.20230909-154651-313421-Uctor	0,987	0,955
LH.20230909-154717-342029-5YbCi	0,985	0,953
LH.20230909-163551-960930-aGEIh	0,992	0,22
LH.20230909-163602-983301-NzJxo	0,992	-0,148
W.20230917-045839-115959-MAQJ4	0,974	0,68
KC.20230919-153229-046788-ZTBD5	0,988	0,832
KC.20230919-200905-422000-BuuXP	0,954	0,866
KC.20230919-210702-646795-NtQek	0,914	0,659
KC.20230919-224241-493439-KFE1M	0,992	0,695
KC.20230919-233504-836152-eyBkv	0,981	0,814
OJ.20230922-045352-796815-KIvBH	0,915	0,913
OJ.20230922-045427-522624-OtxU2	0,924	0,936
OJ.20230922-064325-146027-RBWAc	0,883	0,578
OJ.20230922-064550-334839-fAonB	0,894	0,631
OJ.20230922-065359-186625-D0RI0	0,952	0,896
OJ.20230922-234520-464434-4x49z	0,969	0,871
Portfólió	0,997	0,967

**Ezért a H3 hipotézist igazoltnak tekintem.**

A fejezet lezárásaként a 34. táblázatban összefoglalom a hipotéziseket és a vizsgálatok eredményét.

34. táblázat: Hipotézisvizsgálatok eredményei

*Forrás: Saját szerkesztés*

Száma	Tartalma	Eredménye
H1A	A tradicionális befektetési modell – megvesz és tart – alkalmazásával sikeresebben lehet kereskedni a határidős piacokon, mint egy felépített kereskedési algoritmus alkalmazásával.	Elvetve
H1B	A gépi modell által alkotott algoritmusokkal nyereségesebben lehet kereskedni, mint egy egyszerű, általánosan ismert stratégiával (mozgóátlag keresztezés).	Igazolva
H2A	Meghatározható egy olyan indikátor- és paraméterkészlet, ami alapján a számítógép vezérelt algoritmikus modell hosszú távon sikeresen tud kereskedni.	Igazolva
H2B	Bizonyítható, hogy az adott piacon jobban teljesítő indikátorokon alapuló rendszerek összesített teljesítménye nagyobb lesz, mint az összes indikátor segítségével generált rendszerek összesített teljesítménye.	Igazolva
H3	Igazolható, hogy a különböző indikátorokon alapuló diverzifikált rendszerek összesített, mintán kívüli kereskedési eredménye kiegyensúlyozottabb, mint egy-egy rendszer különálló eredménye.	Igazolva

#### 4.9. 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 disszertációmban 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.

## 5. 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 4.1.-4.5. pontokat 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.



## 6. ÖSSZEFOGLALÁS

Disszertációmban az elmúlt szűk két évtized során a pénzügyi világában megszerzett ismereteimet, tapasztalataimat használtam fel ahhoz, hogy olyan algoritmikus kereskedési stratégiákat fejlesszek ki, melyek élő kereskedésben is konzisztens és hosszú távú profitot generálnak és megállják a helyüket mind a tradicionális kereskedési modellel, mind pedig az egyszerű kereskedési stratégiával szemben is. Dolgozatom első részében részletes és széleskörű szakirodalmi kutatást végeztem, mely hozzásegített a megfogalmazott kutatási céljaim eléréséhez. Meglátásom szerint mind a szakirodalmi feldolgozás, mind pedig a kutatás során létrejött algoritmikus rendszerek olyan következtetésekre vezetnek, melyek tudományosan újszerű ismereteket eredményeznek.

Fontosnak tartottam, hogy körültekintően feldolgozzam, hogy milyen jelentősége van a mesterséges intelligenciának, illetve részterületeinek a gépi tanulásnak és a fejlett genetikai algoritmusoknak nem csak a stratégiaalkotásban, hanem a kereskedési folyamat egészében beleértve a döntéshozatalt és a végrehajtást is. Napjainkban a technológia lehetőséget biztosít arra, hogy a fejlett keresési algoritmusok és mesterséges intelligencia használatával lényegesen hatékonyabban és nem utolsó sorban gyorsabban építsünk kereskedési rendszereket. De a folyamat itt nem ér véget, ugyanis a gépi tanulás eszközeivel lehetőségünk nyílik a rendszerek elemzésére, illetve robusztusságuk vizsgálatára. Így végeredményként olyan stratégiákat kapunk, melyek profit görbéje nagy valószínűséggel fog folytatódni a jövőbeli árfolyamadaton történő futtatás során is.

Az disszertációban szereplő elemzés rámutat arra, hogy ugyan a jövőt nem ismerjük, de az emberi természet és ezen keresztül az árfolyamokat elemezhetjük, mintákat kereshetünk benne, melyeket utána kivetíthetünk és alkalmazhatunk az ismeretlenre, bízva abban, hogy az árfolyamminták ismétlődni fognak. A gépi modellépítés eszközei nem csak hatékonyabbá teszik ezt a folyamatot, hanem sokkal inkább lehetővé teszik azt.

Összességében megállapítható, hogy az általam definiált gépi modellépítés folyamatával sikeres kereskedési algoritmusok építhetők, melyek az elvárt profitot hosszú távon képesek biztosítani, sőt eredményei a tradicionális befektetési modellt és az egyszerű kereskedési stratégiát is képesek túlszárnyalni. A folyamatot, illetve a lépéseket a szakirodalom alapján alakítottam ki, ugyanakkor azok sorrendjét és a változóit saját magam határoztam meg. Fontosnak tartottam azt is, hogy a folyamat megismételhető és kiterjeszhető legyen más pénzügyi eszköz árfolyamára egyaránt. Úgy gondolom, hogy a disszertációmban kidolgozott módszertan segítségével

bizonyos hatékonysággal bármilyen likvid pénzügyi eszköz kereskedésére ki lehet dolgozni algoritmikus kereskedési modelleket.

## 7. SUMMARY

In my dissertation, I used my knowledge and experience gained in the financial world over the past two decades to develop algorithmic trading strategies that generate consistent and long-term profits in live trading and stand up to both the traditional trading model and a simple trading strategy. In the first part of my thesis, I carried out a detailed and extensive literature research, which helped me to achieve my stated research goals. In my view, collecting and processing the literature as well as creating the algorithmic systems lead to conclusions that result in scientifically novel knowledge.

I emphasized the importance of artificial intelligence and its subfields of machine learning and advanced genetic algorithms not only in strategy creation, but also in the trading process as a whole, including decision-making and execution. Nowadays, technology provides the opportunity to build trading systems significantly more efficiently and, last but not least, faster by using advanced search algorithms and artificial intelligence. The process is not interrupted here, because with the tools of machine learning we have the opportunity to analyze the systems and examine their robustness. Thus, as a final result, we get strategies whose profit curve will more likely continue when running them in the future on unknown price data.

The analysis in the dissertation points out that although we do not know the future, we can analyze human nature and through it the prices. We can look for patterns in it, which we can then project and apply to the unknown, trusting that these patterns will repeat themselves. Machine model building tools not only make this process more efficient, but rather make it possible.

Overall, it can be concluded that successful trading algorithms can be built with the process of machine model building that I have defined, which can ensure the expected profit in the long term. I created the process and the steps based on the literature, but at the same time I determined their sequence and variables myself. I also considered it important that the process could be repeated and extended to other financial instruments as well. I believe that with the help of the methodology developed in my dissertation, algorithmic trading models can be developed for any liquid financial instrument with a certain efficiency.

## MELLÉKLETEK

### M1: Irodalomjegyzék

1. Achelis, S. B. (2001). *Technical analysis from A to Z* (2nd ed). McGraw Hill.
2. Ammous, S. (2021). *The bitcoin standard: The decentralized alternative to central banking*. Wiley.
3. 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>
4. Bacidore, J. M. (2020). *Algorithmic trading: A practitioner's guide*. TBG Press.
5. Bandy, H. B. (2015). *Quantitative technical analysis: An integrated approach to trading system development and trade management*. Blue Owl Press, Inc.
6. Bartram, S. M., & Grinblatt, M. (2018). Agnostic fundamental analysis works. *Journal of Financial Economics*, 128(1), 125–147.  
<https://doi.org/10.1016/j.jfineco.2016.11.008>
7. Bihary, Z., Csóka, P., & Szabó, D. Z. (2020). Spectral risk measure of holding stocks in the long run. *Annals of Operations Research*, 295(1), 75–89.  
<https://doi.org/10.1007/s10479-020-03678-6>
8. Bihary, Z., & Víg, A. A. (2020). Heterogén kereskedési stratégiák hatása a piaci árfolyamokra. *Közgazdasági Szemle*, 67(7–8), 688–707.  
<https://doi.org/10.18414/KSZ.2020.7-8.688>
9. Bollen, J., Mao, H., & Zeng, X. (2011). Twitter mood predicts the stock market. *Journal of Computational Science*, 2(1), 1–8.  
<https://doi.org/10.1016/j.jocs.2010.12.007>
10. Bollinger, J. (2002). *Bollinger on Bollinger bands*. McGraw-Hill.
11. Borch, C. (2022). Machine learning and social theory: Collective machine behaviour in algorithmic trading. *European Journal of Social Theory*, 25(4), 503–520.  
<https://doi.org/10.1177/13684310211056010>

12. Brealey, R. A., Myers, S. C., & Marcus, A. J. (2020). *Fundamentals of corporate finance* (Tenth edition, international student edition). McGraw-Hill Education.
13. Brunton, S. L., & Kutz, J. N. (2019). *Data-driven science and engineering: Machine learning, dynamical systems, and control*. Cambridge University Press.  
<https://doi.org/10.1017/9781108380690>
14. Chan, E. P. (2013). *Algorithmic trading: Winning strategies and their rationale*. Wiley.
15. Chang, M., Gould, J., Huang, Y., Treepongkaruna, S., & Yang, J. W. (2022). Insider trading and the algorithmic trading environment. *International Review of Finance*, 22(4), 725–750. <https://doi.org/10.1111/irfi.12367>
16. 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>
17. Chen, Y.-J., Chen, Y.-M., & Lu, C. L. (2017). Enhancement of stock market forecasting using an improved fundamental analysis-based approach. *Soft Computing*, 21(13), 3735–3757. <https://doi.org/10.1007/s00500-016-2028-y>
18. Chung, H., & Shin, K. (2020). Genetic algorithm-optimized multi-channel convolutional neural network for stock market prediction. *Neural Computing and Applications*, 32(12), 7897–7914. <https://doi.org/10.1007/s00521-019-04236-3>
19. CME Group. (2013). *A Trader's Guide to Futures: Guide*. CMGE Group.
20. Csuta, Á. K., & Dobák, D. (2023). Genetikus algoritmus logisztikai alkalmazhatósága. *Mesterséges intelligencia*, 5(1), 21–34. <https://doi.org/10.35406/MI.2023.1.21>
21. Dahal, K. R., Pokhrel, N. R., Gaire, S., Mahatara, S., Joshi, R. P., Gupta, A., Banjade, H. R., & Joshi, J. (2023). A comparative study on effect of news sentiment on stock price prediction with deep learning architecture. *PLOS ONE*, 18(4), e0284695.  
<https://doi.org/10.1371/journal.pone.0284695>
22. Davey, K. J. (2014). *Building winning algorithmic trading systems: A trader's journey from data mining to Monte Carlo simulation to live trading*. Wiley.
23. Day, M.-Y., Yang, C.-Y., & Ni, Y. (2023). Portfolio dynamic trading strategies using deep reinforcement learning. *Soft Computing*. <https://doi.org/10.1007/s00500-023-08973-5>

24. Domowitz, I., & Yegerman, H. (2005). The Cost of Algorithmic Trading: A First Look at Comparative Performance. *The Journal of Trading*, 1(1), 33–42.  
<https://doi.org/10.3905/jot.2006.609174>
25. Douglas, M. (2000). *Trading in the zone: Master the market with confidence, discipline and a winning attitude*. New York Institute of Finance.
26. Dubey, R. K., Babu, A. S., Jha, R. R., & Varma, U. (2022). Algorithmic Trading Efficiency and its Impact on Market-Quality. *Asia-Pacific Financial Markets*, 29(3), 381–409. <https://doi.org/10.1007/s10690-021-09353-5>
27. Ehlers, J. F. (2004). *Cybernetic analysis for stocks and futures: Cutting-edge DSP technology to improve your trading*. John Wiley.
28. Emami, H. (2022). Stock exchange trading optimization algorithm: A human-inspired method for global optimization. *The Journal of Supercomputing*, 78(2), 2125–2174.  
<https://doi.org/10.1007/s11227-021-03943-w>
29. Fabozzi, F. J. (2009). *Institutional investment management: Equity and bond portfolio strategies and applications*. John Wiley & Sons.
30. Fang, J., Qin, Y., & Jacobsen, B. (2014). Technical market indicators: An overview. *Journal of Behavioral and Experimental Finance*, 4, 25–56.  
<https://doi.org/10.1016/j.jbef.2014.09.001>
31. 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>
32. Hatch, B. C., Johnson, S. A., Wang, Q. E., & Zhang, J. (2021). Algorithmic trading and firm value. *Journal of Banking & Finance*, 125, 106090.  
<https://doi.org/10.1016/j.jbankfin.2021.106090>
33. Hieronymus, T. A. (2022). *Economics of Futures Trading For Commercial and Personal Profit*. Ceres Books.
34. Hooper, J., Zalewski, A., & Watanabe, E. (2013). *Advanced charting techniques for high probability trading: The most accurate and predictive charting method ever created* [Electronic resource]. John Wiley & Sons.

35. 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>
36. Hull, J. (2017). *Fundamentals of futures and options markets* (eighth edition, global edition). Pearson.
37. Hung, C.-C., & Chen, Y.-J. (2021). DPP: Deep predictor for price movement from candlestick charts. *PLOS ONE*, 16(6), e0252404.  
<https://doi.org/10.1371/journal.pone.0252404>
38. Kaufman, P. J. (2013). *Trading systems and methods* (Fifth Edition) [Electronic resource]. John Wiley & Sons, Inc.
39. Kissell, R. (2020). *Algorithmic trading methods: Applications using advanced statistics, optimization, and machine learning techniques* (2. kiad.). Elsevier Inc.
40. Kovács, L., & Tetrák, E. (2019). *Financial Literacy Theory and Evidence*.
41. Kumar, G., Jain, S., & Singh, U. P. (2021). Stock Market Forecasting Using Computational Intelligence: A Survey. *Archives of Computational Methods in Engineering*, 28(3), 1069–1101. <https://doi.org/10.1007/s11831-020-09413-5>
42. Kühn, 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>
43. Lam, J. (2017). *Implementing enterprise risk management: From methods to applications*. John Wiley & Sons, Inc.
44. Lin, Z. (2018). Modelling and forecasting the stock market volatility of SSE Composite Index using GARCH models. *Future Generation Computer Systems*, 79, 960–972.  
<https://doi.org/10.1016/j.future.2017.08.033>
45. Liu, P., Zhang, Y., Bao, F., Yao, X., & Zhang, C. (2023). Multi-type data fusion framework based on deep reinforcement learning for algorithmic trading. *Applied Intelligence*, 53(2), 1683–1706. <https://doi.org/10.1007/s10489-022-03321-w>

46. Macedo, L. L., Godinho, P., & Alves, M. J. (2020). A Comparative Study of Technical Trading Strategies Using a Genetic Algorithm. *Computational Economics*, 55(1), 349–381. <https://doi.org/10.1007/s10614-016-9641-9>
47. Manahov, V. (2018). The rise of the machines in commodities markets: New evidence obtained using Strongly Typed Genetic Programming. *Annals of Operations Research*, 260(1–2), 321–352. <https://doi.org/10.1007/s10479-016-2286-1>
48. McAllen, F. (2016). *Charting and technical analysis*. Fred McAllen.
49. Muravyev, D., & Picard, J. (2022). Does trade clustering reduce trading costs? Evidence from periodicity in algorithmic trading. *Financial Management*, 51(4), 1201–1229. <https://doi.org/10.1111/fima.12405>
50. Nassar, D. S. (2006). *Ordinary people, extraordinary profits: How to make a living as an independent stock, options, and futures trader*. Wiley.
51. 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>
52. Nison, S. (2001). *Japanese candlestick charting techniques: A contemporary guide to the ancient investment techniques of the Far East* (2. ed). New York Institute of Finance.
53. Pardo, R. (2008). *The evaluation and optimization of trading strategies* (2. ed). Wiley.
54. Patton, A. J., & Sheppard, K. (2015). Good Volatility, Bad Volatility: Signed Jumps and The Persistence of Volatility. *Review of Economics and Statistics*, 97(3), 683–697. [https://doi.org/10.1162/REST\\_a\\_00503](https://doi.org/10.1162/REST_a_00503)
55. Person, J. L. (2004). *A complete guide to technical trading tactics: How to profit using pivot points, candlesticks & other indicators*. J. Wiley.
56. Person, J. L. (2013). *Mastering the stock market: High probability market timing & stock selection tools* [Electronic resource]. John Wiley & Sons.
57. Picasso, A., Merello, S., Ma, Y., Oneto, L., & Cambria, E. (2019). Technical analysis and sentiment embeddings for market trend prediction. *Expert Systems with Applications*, 135, 60–70. <https://doi.org/10.1016/j.eswa.2019.06.014>



58. Poitras, G. (2009). From Antwerp to Chicago: The History of Exchange Traded Derivative Security Contracts. *Revue d'Histoire des Sciences Humaines*, 20(1), 11. <https://doi.org/10.3917/rhsh.020.0011>
59. Pothumsetty, R. (2020). APPLICATION OF ARTIFICIAL INTELLIGENCE IN ALGORITHMIC TRADING. *International Journal of Engineering Applied Sciences and Technology*, 04(12), 140–149. <https://doi.org/10.33564/IJEAST.2020.v04i12.019>
60. Prabheesh, K. P., Padhan, R., & Garg, B. (2020). COVID-19 and the Oil Price – Stock Market Nexus: Evidence From Net Oil-Importing Countries. *Energy RESEARCH LETTERS*, 1(2). <https://doi.org/10.46557/001c.13745>
61. Rahiminezhad Galankashi, M., Mokhatab Rafiei, F., & Ghezelbash, M. (2020). Portfolio selection: A fuzzy-ANP approach. *Financial Innovation*, 6(1), 17. <https://doi.org/10.1186/s40854-020-00175-4>
62. Reddy, H. T. (2013). *The trading methodologies of W.D. Gann: A guide to building your technical analysis toolbox*. FT Press.
63. Refco Private Client Group (Szerk.). (2005). *The complete guide to futures trading: What you need to know about the risks and rewards*. J. Wiley & Sons, Inc.
64. Scarpino, M. (2019). *Algorithmic trading with interactive brokers (Python and C)*. Quiller Technologies LLC.
65. Schroeder, A. (2008). *The snowball: Warren Buffett and the business of life*. Bantam Books.
66. Schulmerich, M., Leporcher, Y.-M., & Eu, C.-H. (2015). *Applied asset and risk management: A guide to modern portfolio management and behavior-driven markets*. Springer.
67. Schwager, J. D. (2017). *A complete guide to the futures market: Technical analysis and trading systems, fundamental analysis, options, spreads, and trading principles* (Second edition). Wiley.
68. Sezer, O. B., & Ozbayoglu, A. M. (2018). Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. *Applied Soft Computing*, 70, 525–538. <https://doi.org/10.1016/j.asoc.2018.04.024>

69. Shah, D., Isah, H., & Zulkernine, F. (2019). Stock Market Analysis: A Review and Taxonomy of Prediction Techniques. *International Journal of Financial Studies*, 7(2), 26. <https://doi.org/10.3390/ijfs7020026>
70. Shi, F., Broussard, J. P., & Booth, G. G. (2022). The complex nature of financial market microstructure: The case of a stock market crash. *Journal of Economic Interaction and Coordination*. <https://doi.org/10.1007/s11403-021-00343-4>
71. Silva, A., Neves, R., & Horta, N. (2015). A hybrid approach to portfolio composition based on fundamental and technical indicators. *Expert Systems with Applications*, 42(4), 2036–2048. <https://doi.org/10.1016/j.eswa.2014.09.050>
72. Smith, B. M. (2004). *A history of the global stock market: From ancient Rome to Silicon Valley*. Univ. of Chicago Press.
73. Thackray, A., & Brock, D. C. (2015). *Moore's law: The life of Gordon Moore, Silicon Valley's quiet revolutionary*. Basic Books, a member of the Perseus Books Group.
74. Thawornwong, S., & Enke, D. (2004). The adaptive selection of financial and economic variables for use with artificial neural networks. *Neurocomputing*, 56, 205–232. <https://doi.org/10.1016/j.neucom.2003.05.001>
75. Théate, T., & Ernst, D. (2021). An application of deep reinforcement learning to algorithmic trading. *Expert Systems with Applications*, 173, 114632. <https://doi.org/10.1016/j.eswa.2021.114632>
76. Thomsett, M. C. (1998). *Mastering fundamental analysis*. Dearborn Financial Pub.
77. Thomsett, M. C. (1999). *Mastering fundamental analysis: How to spot trends and pick winning stocks like the pros*. Dearborn ; BRAD.
78. Wang, Z. (2015). *High-frequency trading and probability theory*. World Scientific.
79. Williams, J. (1987). *The economic function of futures markets* (Repr). Cambridge Univ. Pr.
80. Yoon, H.-S. (2021). Time Series Data Analysis using WaveNet and Walk Forward Validation. *Journal of the Korea Society for Simulation*, 30(4), 1–8. <https://doi.org/10.9709/JKSS.2021.30.4.001>

81. Zhong, X., & Enke, D. (2019). Predicting the daily return direction of the stock market using hybrid machine learning algorithms. *Financial Innovation*, 5(1), 24.  
<https://doi.org/10.1186/s40854-019-0138-0>

## M2: Ábrajegyzék

1. ábra: S&P 500 tőzsdeindex inflációval módosítva.....	8
2. ábra: Tick adatok megjelenítése CVGI részvényen .....	13
3. ábra: CVGI részvény vonal diagramja .....	13
4. ábra: Bar intervallum értelmezése .....	14
5. ábra: Árfolyam értelmezése napon belül és napi intervallumban .....	15
6. ábra: Üres és teli gyertya ábrázolása .....	16
7. ábra: Trendek megjelenítése gyertya diagrammal E-mini S&P 500 határidős szerződésen .	16
8. ábra: E-mini S&P 500 ábrázolása Kagi diagramon 10 pontos visszafordulási árral.....	17
9. ábra: E-mini S&P 500 ábrázolása Kase diagramon 10 pontos intervallum árral.....	18
10. ábra: E-mini S&P 500 ábrázolása pont és ábra diagramon 2 pontos doboz és 5 pontos visszafordulási árral.....	19
11. ábra: Arany 2023 decemberi határidős szerződés árfolyama.....	23
12. ábra: Olaj határidős szerződés 2020 május .....	24
13. ábra: Indikátorok csoportosítása.....	29
14. ábra: 20 és 200 periódusú mozgó átlagok .....	30
15. ábra: Bollinger szalag alkalmazása .....	31
16. ábra: Sztochasztikus indikátor alkalmazása .....	32
17. ábra: VWAP indikátor alkalmazása .....	33
18. ábra: ATR indikátor alkalmazása .....	34
19. ábra: Pivot pontok megjelenítése az árfolyamgrafikonon .....	35
20. ábra: Rendelési könyv keresleti és kínálati oldala.....	41
21. ábra: A rendszerépítés legfontosabb aspektusai .....	48
22. ábra: Tanulási-tesztelési intervallumok lehetséges meghatározási módjai .....	51
23. ábra: Sziklás és csúcsos optimalizációs tér .....	56
24. ábra: Walk forward analízis .....	57
25. ábra: Optimális indikátorkészlet meghatározása .....	64
26. ábra: LH rendszerek összesített profit görbéje .....	73
27. ábra: Búza (W) rendszerek összesített profit görbéje.....	80
28. ábra: Kávész (KC) rendszerek összesített profit görbéje.....	87
29. ábra: Fagyasztott narancslé (OJ) rendszerek összesített profit görbéje.....	94
30. ábra: A portfólió összesített profit görbéje.....	97

31. ábra: Sovány sertés (LH), búza (W), kávé (KC), fagyasztott narancslé (OJ) árfolyamának alakulása a validációs időszakban .....	98
32. ábra: Az egyszerű modell profit görbéje a vizsgált időszakban .....	101

### M3: Táblázatjegyzék

1. táblázat: Roidia Trading Funds nettó havi hozamok (%).....	9
2. Táblázat: Rendszerépítés indikátorai.....	62
3. táblázat: Indikátorok előfordulási gyakorisága sovány sertés (LH) rendszerekben.....	68
4. táblázat: Sovány sertés (LH) rendszerek átlag statisztikái .....	69
5. táblázat: Kiválasztott sovány sertés (LH) rendszerek .....	69
6. táblázat: Sovány sertés (LH) rendszerek WF elemzés és verifikálás eredménye.....	71
7. táblázat: Sovány sertés (LH) rendszerek validációs eredményei .....	72
8. táblázat: LH rendszerek korrelációs mátrixa.....	74
9. táblázat: Indikátorok előfordulási gyakorisága búza (W) határidős rendszereknél.....	75
10. táblázat: Búza (W) rendszerek átlag statisztikái.....	76
11. táblázat: Búza (W) határidős szerződéseken kiválasztott rendszerek .....	77
12. táblázat: Búza (W) rendszerek WF elemzés és verifikálás eredménye .....	79
13. táblázat: Búza (W) rendszerek validációs eredményei.....	80
14. táblázat: Búza (W) rendszerek korrelációs mátrixa .....	81
15. táblázat: Indikátorok előfordulási gyakorisága kávé (KC) határidős szerződéseknél.....	82
16. táblázat: Kávé (KC) határidős rendszerek átlag statisztikái .....	83
17. táblázat: Kiválasztott rendszerek kávé (KC) határidős piacokra.....	84
18. táblázat: Kávé (KC) rendszerek WF elemzése és verifikálás eredménye .....	86
19. táblázat: Kávé (KC) rendszerek validációs eredményei.....	87
20. táblázat: Kávé (KC) rendszerek korrelációs mátrixa .....	88
21. táblázat: Indikátorok előfordulási gyakorisága fagyasztott narancslé (OJ) határidős szerződéseknél.....	89
22. táblázat: Fagyasztott narancslé (OJ) határidős rendszerek átlag statisztikái .....	90
23. táblázat: Kiválasztott rendszerek fagyasztott narancslé (OJ) határidős piacokra.....	91
24. táblázat: Fagyasztott narancslé (OJ) rendszerek WF elemzése és verifikálás eredménye ..	93
25. táblázat: Fagyasztott narancslé (OJ) rendszerek validációs eredményei.....	94
26. táblázat: Fagyasztott narancslé (OJ) rendszerek korrelációs mátrixa .....	95
27. táblázat: A portfólió összesített eredményei .....	96
28. táblázat: A tradicionális modell eredményei .....	99
29. táblázat: Egyszerű kereskedési stratégia eredményei a validációs időszakban.....	100
30. táblázat: Gépi modell és egyszerű stratégia eredményei.....	103
31. táblázat: Sikeresen verifikált és tesztelt rendszerek .....	103

32. táblázat: Optimális indikátorkészlettel épített rendszerek mérőszámainak változása.....	107
33. táblázat: Rendszerek és teljes portfólió korrelációs együtthatói .....	108
34. táblázat: Hipotézisvizsgálatok eredményei .....	109