

# **DOKTORI (PHD) ÉRTEKEZÉS TÉZISEI**

**Barta kos**  
**GDLL**  
**2024**



**Magyar Agrár- és Élettudományi  
Egyetem**

**OLAJÁR ELŐREJELZÉS MESTERSÉGES  
NEURÁLIS HÁLÓK ALKALMAZÁSÁVAL A  
WALL STREET JOURNAL CIKKEIRE  
ALAPOZVA**

DOI: 10.54598/004540

**DOKTORI (PHD.) ÉRTEKEZÉS TÉZISEI**

**BARTA ÁKOS**

**GÖDÖLLŐ**

**2024**

## **A doktori iskola**

**megnevezése:** Gazdaság- és Regionális Tudományi Doktori Iskola

**tudományága:** gazdálkodás és szervezéstudomány

**vezetője:** **Dr. Bujdosó Zoltán PhD**  
egyetemi tanár  
Magyar Agrár- és Élettudományi Egyetem  
Fenntartható Fejlesztés és Gazdálkodás Intézet

**Témavezető(k):** **Dr. habil Molnár Márk PhD**  
egyetemi docens  
Eötvös Lóránd Tudományegyetem  
Gazdaságtudományi Kar  
Összehasonlító Gazdaságtan Tanszék

**Dr. Naárné Dr. Tóth Zsuzsanna Éva PhD**  
egyetemi docens  
Budapesti Metropolitan Egyetem  
Gazdaságtudományi Intézet

.....

Az iskolavezető jóváhagyása

.....

A témavezető(k) jóváhagyása

## Tartalomjegyzék

1.	A munka előzményei, célkitűzések .....	5
2.	Anyag és módszer .....	9
3.	Eredmények.....	14
4.	Következtetések és a javaslatok. ....	20
5.	Új tudományos eredmények.....	21
6.	A szerzőnek az értekezés témaköréhez kapcsolódó publikációi ...	23
7.	Irodalomjegyzék.....	26

## 1. A munka előzményei, célkitűzések.

Több mint 40 év telt el az 1973-as első olajár-sokk óta. Ebben az időszakban az olaj iránti globális kereslet drámaian megnőtt, miközben az új energiával kapcsolatos technológiák és új energiaforrások ellenállóbbá tették a globális fogyasztókat az olajsokkokkal szemben. Az 1970-es évek olajsokkjai óta a feltörekvő gazdaságok szerepen jelentősen megnövekedett a globális energiafogyasztásban. A Kínai Népköztársaság részesedése például ötször nagyobb, mint az 1970-es években volt. Másrészt a legnagyobb (USA) és a jelenlegi harmadik legnagyobb (Japán) olajfogyasztók részesedése az 1970-es évek óta csökkent, az Egyesült Államoké 32%-ról 21%-ra, Japáné 10%-ról 5%-ra.

Az 1970-es évek olajválságait és az azt követő gazdasági recessziókat követően több tanulmány is megállapította, hogy az olajársokkok jelentős szerepet játszottak a gazdasági visszaesésekben. Az elmúlt években az olajárak 2001-ben megkezdődött meredek emelkedése és a másodlagos jelzáloghitelválságot követő 2008-as meredek csökkenés újra felkeltette az érdeklődést az olajárak makrogazdaságra gyakorolt hatásai iránt.

A fosszilis tüzelőanyagok továbbra is a jelenlegi globális energiafelhasználás jelentős részét fedezik, 2020-ban ennek megfelelő 80%-os részesedéssel. (IEA, 2020). Az olaj továbbra is a világ vezető üzemanyaga, 2020-ban a globális energiafogyasztás 31,2%-át tette ki, ami azt jelzi, hogy a kőolaj továbbra is fontos a nemzetközi tényezőpiacokon. Ezért a kőolajár-determinánsok történeti fejlődésének megértése a gazdaságpolitikai tervezés érdekében kiemelten fontos kutatási kérdés. E tekintetben a kőolajpiacon az új évezred első évtizedében tapasztalható ármozgások főként két okból keltették fel a figyelmet: egyrészt az 1980-as és 1990-es évek alatti alacsony szintről több éven keresztül emelkedett az ár, amely rekordot döntött. Az árak ezen alakulása széleskörű vitát váltott ki egy újabb olajválságról, utalva az 1970-es és 1980-as évek két olajválságára. Másodszor, ami még fontosabb, az első két olajválsággal ellentétben ennek a mostani árcsúcsnak az oka nem egyértelmű: egyszerre több potenciálisan releváns fejlemény zajlott le, ami megnehezíti azok árra gyakorolt hatásának azonosítását. A gazdasági szakirodalomban egyre több cikk tanúskodik erről. Az akadémiai diskurzus általában három magyarázat között ingadozik, tükrözve a kőolaj árára ható piaci erőket: először is azt állítják, hogy az áremelkedés a kőolajkészletek végeességét és a termelési kapacitások további bővítésének képtelenségét mutatja (kínálatvezérelt áremelkedés). (Kaufmann, 2011) Másodszor, feltételezik, hogy a feltörekvő országok, például Kína és India

váratlanul erős gazdasági növekedése eredményezte a kőolaj iránti kereslet váratlan növekedését, ami a kőolaj azonnali szállításának megszorulásához és az ár emelkedéséhez (keresletvezérelt áremelkedés) vezetett. (Hamilton, 2008) (Kilian, 2009) Harmadszor megállapítják, hogy a spekulánsok növekvő száma a kőolajpiacon jelentősen megerősítette az előretekintő keresleti tevékenységek súlyát, és ezzel megváltoztatta az árdinamikát (várakozásvezérelte áremelkedés) (Fattouh, Kilian, & Mahadeva, 2013)

Abból kiindulva, hogy a kőolaj az egyik legfontosabb nyersanyag, az áringadozás jelentős világ gazdasági hatással bír. Ebből kifolyólag a gazdaság szereplői igyekeznek előrejelezni az árfolyam változásait, a trendeket, a jövőbeli értékeket. Mivel a gazdasági szereplők nagy része nincs piacbefolyásoló pozícióban, így a hozzá beérkező információkból igyekszik ezen adatokat és információkat kinyerni.

A mai felgyorsult világban az információ óriási tömegével szembesülünk. Clickbait cikkek, hitelesnek vélt források ezrei állnak rendelkezésre, amelyekből igyekszünk kigyűjteni a számunkra hasznos információkat. A kulcs tehát nem feltétlenül az információ vagy hír beszerzése, hanem az információáradatból kiszűrni a releváns információtartalmat, majd azt hatékonyan feldolgozni. A probléma összetett és a gazdasági szereplők egyre komplexebb információfeldolgozási és szűrési metódusokat alkalmaznak, egyre bonyolultabb információs hálózatokból és nagy adatmennyiségből igyeksenek kiszűrni a zajt, vagyis a fals információkat, kiegészítő tényeket.

Jelen dolgozat témája az olajárfolyam elemzése egy komplexebb megközelítés alkalmazásával. Mivel mindenkit érint, illetve közvetetten minden iparágra kihatása van, így nagy szereppel bír. Oligopol piacon működik, vagyis a szereplők nagy figyelmet fordítanak a többi szereplő döntéseire. Mivel relatíve nagy a piaci részesedése egy-egy szereplőnek, így nagy hatással bírhatnak. Felhasználóként, végfogyasztóként ráhatás nincs a piacra, de a nagy információtömegből egy speciális szűrőt szükséges alkalmaznunk, hogy tudjuk mely híreket érdemes komolyan venni.

Az elmúlt években egyre nagyobb teret hódítanak a neurális hálók, melyek nem statisztikai alapokon képesek összefüggéseket és következtetéseket, kapcsolatokat felismerni adathalmazok pontjai között, mint például a hírek. A neurális hálók az 1940-es éves környékén indultak fejlődésnek, a számítástechnika fejlődésével párhuzamosan. Eleinte kapacitáskorlátok is voltak, de a jelenlegi technológia fejlettség mellett az ilyen fejlesztések fénykorukat élik. Az információfeldolgozás módszere a neurális hálók esetében nagyban hasonlít

az emberi agyban jelenlévő hálózathoz, nem feltétlenül statisztikai alapon működik. Mindamellett jóval gyorsabb és hatékonyabb, mint amire az ember képes lesz/lehet.

Feltételezésem az, hogy a gazdasági és politikai hírekkel kapcsolatos újságcikkek tartalma alapján előre jelezhető az olajár változása, legalábbis bizonyos szinten. Az újságcikkekben szereplő gazdasági és politikai információk segítségével meg lehet válaszolni a kérdést, hogy milyen változás várható az olajárakban. A hírekben szereplő információk alapján előre látható véleményem szerint, hogy mikor várható növekedés vagy csökkenés az olajárakban, valamint a változás mértéke is.

Valószínűsíthető, ha az írott vagy elektronikus sajtóban pozitív, vagy negatív véleményeket közölnek az olajárakra vonatkozóan, akkor ez hatással lehet a vevők és vezetők döntéseire, amelyek végeredményeként befolyásolhatják az olajárak változását. A hírek alapján tehát spekulatív alapokon nyugvó döntéseket hoznak a piaci szereplők, amelyek keresleti vagy kínálati oldali változás miatt tényleges árváltozást fognak eredményezni, úgy, hogy az eredetileg véleményezett és valószínűsített eredmény esetleg be sem következi.

Fontos kijelenteni, hogy gazdasági szereplők alatt olyan háztartásokat, cégeket értek, akik ugyan rendelkeznek információkkal, de nem „tűzközeliak”, vagyis másodkézből tudnak értesülni és alapoznak a szaksajtó hitelességére.

A jelenlegi információdömpingben a gazdasági aktorok igyekeznek feldolgozni a rendelkezésre álló információkat. Az információfeldolgozás során szükséges kiszűrni a nem valid információt, illetve súlyozni az egyes tények vagy vélemények befolyását. Ezáltal feltételezhetjük azt, hogy a híreknek és információknak manipulációs jellege van. Az olajár vonatkozásában, ami egy oligopol piac jellemző mutatója, ahol a termelési döntéshozatal nem nyilvános, a gazdasági aktorok nagymértékben támaszkodhatnak a hírekre.

Az értekezés módszertanilag alapvetően a mesterséges neurális hálók alkalmazására épül, amik jelenleg fénykorukat élik, egyre szervezettebben befollyva életünkbe. A módszertan hasznossága, felépítése és fejlesztése véleményem szerint az elkövetkezendő időszak egyik fő témaköre lesz. Ebből adódóan a neurális hálók tudományos és napi életbe való alkalmazhatóságát vizsgálom, pontosabban mennyire tudja segíteni napi tevékenységünket és döntéshozatali módszerünket.

Kutatásom során célom, hogy bebizonyítsam, hogy az információáramot elemezve (vagyis híreket, sajtóinformációt, nem pedig fundamentális adatokat)

van kapcsolat az olajárfolyam és a sajtóhírek között, ezáltal egyrészt alkalmazható előrejelzésként, másrészt kimutatható a spekuláció alapú árfolyammozgás.

A témakör, illetve a kutatás kapcsán az alábbi hipotéziseket fogalmazom meg, melyeket kutatásom során vizsgálni fogok:

- [1] A mesterséges neurális hálózatok képesek hatékony információfeldolgozásra, vagyis nagy adattömegek (Big Data) gyors és hatékony elemzésére is használhatóak.
- [2] A vizsgált folyóiratok és az árfolyam között összefüggés mutatható ki, vagyis egyértelműen bizonyítható a spekulációs árfolyammozgás az olajár tekintetében.
- [3] A Wall Street Journal (WSJ) újságcikkek tartalmának mesterséges neurális hálóval (ANN) történő elemzésével kellő pontossággal meghatározható a következő napi olajár változás.
- [4] Az újságcikkek összefoglalásával, vagyis tömörítésével nagymértékben növelhető a mesterséges neurális hálóval történő előrejelzési hatékonyság.
- [5] Az újságcikkek hangulatelemzésével nagymértékben növelhető a mesterséges neurális hálóval történő előrejelzési hatékonyság.
- [6] Az olajárfolyam visszacsatolt neurális hálóval (RNN) történő vizsgálatával, tehát csak az árfolyam historikus mozgásának elemzésével kellő pontossággal meghatározható a következő napi olajár változás.
- [7] A mesterséges neurális háló rejtett rétegeinek és neuronjainak, vagyis háló-részének nagymértékű növelésével jeletősen növelhető a hatékonyság.
- [8] A WSJ újságcikkeinek mesterséges neurális hálóval történő elemzése hatékonyabb, mint az árfolyam visszacsatolt neurális hálóval való elemzése, vagyis az árfolyam mozgásában nagyobb szerepe van a spekulációnak, mint a fundamentumoknak.
- [9] A mesterséges neurális háló segítségével kapott előrejelzés hatékonyabb, mint adott matematikai-tőzsdei modellekkel történő árfolyamváltozás-előrejelzés.



## 2. Anyag és módszer

Az olajár-előrejelző neurális háló (NN) azokat a Wall Street Journal cikkeket használja az elemzéshez, amelyek az olajárakról szólnak, és ezeket az információkat a neurális háló segítségével dolgozza fel.

Az olaj ár-előrejelzést biztosító Neurális Háló használata segít megérteni a piaci feltételek hatását az olaj árra. A kutatók képesek lehetnek megérteni a spekuláción is alapuló piaci feltételek és a Wall Street Journal cikkei közötti összefüggéseket, és ezáltal jobban megérteni a piacok működését, és pontosítani a jövőbeli olaj árakat.

A mesterséges neurális háló (ANN) tanulja a cikk által összefoglalt információkat, amelyek a piaci mozgásokra vonatkoznak, és alkalmazza a következtetések levonásához. Az ANN figyelembe veszi a piaci trendeket, a piaci feszültségeket, a felső- és alsó határokat, és más hasznos információkat, amelyeket a Wall Street Journal cikkeiből vehet ki. Az ANN előrejelzi az olaj árát, és különböző feltételezéseket használ a különböző piaci szituációk megértéséhez. Az ANN ezenkívül figyelembe veszi a technikai elemzést is, és ezen túlmenően a prognózis során használható egyéb technikákat is.

A dolgozatban részletesen ismertettem az ANN és társai működését. A neurális háló lehetővé teszi egy nem megfelelő minőségű megoldás javítását; a hálón tudunk finomítani, majd a modellt újrafuttatni és bízni abban, hogy javul az eredmény.

Világszinten nem létezik egységes olajár, hiszen a kitermelt olaj minősége, oligopol piacok külön határoznak meg árakat. Ugyanakkor az árváltozás iránya, nagysága nagyon hasonló, tehát a különböző árak együttmozognak.

A valóságban számos különböző típusú és minőségű kőolaj létezik – ez a sűrű, feldolgozatlan folyadék, amelyet a fúrótornyok a föld mélyéből termelnek ki –, és némelyik kívánatosabb, mint mások. Például a finomítók könnyebben állítanak elő benzint és gázolajat alacsony kéntartalmú vagy „édes” nyersanyagból, mint a magas kéntartalmú olajból. Az alacsony sűrűségű vagy „könnyű” nyersolaj általában ugyanazon okból kedvez a nagy sűrűségű fajtának. (Jiang, An, Jia, & Sun, 2017)

Az is számít, hogy honnan származik az olaj, ha Ön vevő. Minél olcsóbb a termék szállítása, annál olcsóbb a fogyasztó számára. Szállítási szempontból a

tengeren kitermelt olajnak vannak bizonyos előnyei a szárazföldi készletekhez képest, amelyek a csővezetékek kapacitásától függenek.

E tényezők miatt a kőolaj vásárlóinak – a spekulánsokkal együtt – egyszerű módszerre van szükségük az áru minősége és elhelyezkedése alapján történő értékelésére. Ezt a fontos célt szolgálják az olyan benchmarkok, mint a Brent, a WTI és a Dubai/Oman. Amikor a finomítók Brent-szerződést vásárolnak, határozott elképzelésük van arról, hogy milyen jó lesz az olaj, és honnan származik. Manapság a globális kereskedés nagy része a határidős piacon zajlik, és minden kontraktus egy bizonyos olajkategóriához kötődik.

A kereslet és kínálat dinamikus természete miatt az egyes benchmarkok értéke folyamatosan változik. Hosszú távon diszkonttal is elérhetővé válhat egy másik indexhez prémiummal értékesített marker. (Arshad, Rizvi, Haroon, Mehmood, & Gong, 2021)

A világ összes nyersolajszerződésének nagyjából kétharmada a Brent Crude-ra vonatkozik, így ez a legszélesebb körben használt jelző. Manapság a „Brent” valójában az Északi-tenger négy különböző mezőjéből származó olajra utal: Brent, Forties, Oseberg és Ekofisk. Az ebből a régióból származó nyersolaj könnyű és édes, így ideális dízelüzemanyag, benzin és más nagy keresletű termékek finomításához. Mivel az ellátás vízi úton történik, könnyen szállítható távoli helyekre.

A WTI az Egyesült Államok kútjaiból kitermelt olajra vonatkozik, amelyet csővezetéken az oklahomai Cushingba küldenek. Maga a termék nagyon könnyű és nagyon édes, így különösen benzinfinomításhoz ideális. A WTI továbbra is az Egyesült Államokban fogyasztott olaj fő etalonja.

A közel-keleti nyersolaj hasznos referencia a WTI-nél vagy a Brentnél valamivel gyengébb olajhoz. Dubajból, Ománból vagy Abu Dhabiból származó nyersanyagból álló „kosár”, valamivel nehezebb és magasabb a kéntartalma, így a „savanyú” kategóriába sorolható. Dubai/Omán a fő referencia az ázsiai piacra szállított Perzsa-öböl olaj tekintetében. Az olajpiaci kitermelés oligopol piacot képez, vagyis egyes szereplők döntései, nyilatkozatai, előrejelzései vagy épp lokális válságai nagy hatással lehetnek a piaci árakra.

Habár a Brent jobban tükrözi a világpiaci olajárváltozást, viszont a kutatás további részeit figyelembe véve, vagyis, hogy egy amerikai kiadású újságot vizsgáltam, ami erősen foglalkozik a belföldi olajkitermeléssel, így a cikkekben is gyakran jelenhetnek meg erre vonatkozó utalások, a továbbiakban olajár-benchmarkként a WTI árat használtam.

A weboldalak elemzése során az Wall Street Journal (továbbiakban: WSJ) bizonyult legalkalmasabbnak az elvégzendő kutatás során az adatgyűjtésre, így itt került lefuttatásra a scraper.

A kutatás során a WSJ 2000-2020 között kiadott cikkeit töltöttem le, pontosabban scrapeltem. A cikkek esetében a későbbi esetleges hasznosítás miatt összefoglaltam, vagyis a rövidített verziót is mentettem.

A web scrapelés (webkparás magyarosan), vagyis a webes adatgyűjtés vagy a webes adatkinyerés olyan adatszerzési módszer, amelyet a webhelyekről származó adatok kinyerésére használnak. A web scraper szoftver közvetlenül hozzáférhet a világhálózhoz a Hypertext Transfer Protocol vagy egy webböngésző használatával. Míg az adatgyűjtést a szoftverhasználó manuálisan is elvégezheti, ez a kifejezés általában bottal vagy webrobottal megvalósított automatizált folyamatokra utal. Ez egy olyan másolási forma, amelyben meghatározott adatokat gyűjtenek össze és másolnak a webről, jellemzően egy központi helyi adatbázisba vagy táblázatba, későbbi visszakeresés vagy elemzés céljából.

A kódsor teljes lefutása 1604 órát vett igénybe, vagyis közel 67 napig futott folyamatosan. Visszafejtve egy hónap cikkeit átlagosan 401 perc alatt nézte át és mentette le. A 2000-2020 közötti időszak, vagyis a 21 év összesen 330.435 cikket jelent. Az így készített .xlsx fájl 558 MB méretű lett.

Az adatfeldolgozó rendszerek, amelyek az agyban található neurológiai hálózatokon alapulnak, és azokat felépítése és mintája szerint valósulnak meg programozási környezetben. A rendszereket elsősorban mintazonosításra és -feldolgozásra használják, és a korábbi feladatok elemzési eredményei alapján képesek fokozatosan javítani a teljesítményt. (Jain, Mohiuddin, & Mao, 1996)

A neurális szerveződés és hálózatosodás alapvetően a többrétegű perceptron modellel magyarázható. Ebben a modellben a neurális hálózatok olyan rétegek formájában zajlanak, amelyek egy irányban hoznak létre kapcsolatokat, más néven előreccsatolt neurális hálózatok. A csomópontoknak több rétege van: bemeneti, rejtett és kimeneti. A különböző csomópontok közötti kapcsolatok megváltoztatják a hálózatok viselkedését. A bemeneti rétegek információt kapnak, ekkor a bemeneti és a rejtett rétegek között kapcsolatok jönnek létre. A rejtett rétegek ezt követően feldolgozzák az információt, amely viszont a kimeneti rétegekbe kerül. Végül a kimeneti rétegek a következő réteg bemenetévé válnak, és a sorozat folytatódik. (Xin, 1999)

A mesterséges intelligencia egy olyan számítógépes program, amely az emberi agyhoz hasonló módon képes szervezni az információt. A mesterséges

intelligencia, a neurális hálózatok vegyülete a kognitív tehetséggel és a gépek tervezésével kapcsolatos kutatások eredményeként alakult ki. (Kutsurelis, 1998) A mesterséges intelligencia története Aristo-ig nyúlik vissza. Ismeretes, hogy Aristo a gondolkodás algoritmusán dolgozott, és megvitatta annak nehézségeit is. Modern értelemben a mesterséges intelligencia akkor került be a tudományos világba, amikor az 1940-es években üzembe helyezték az első elektronikus számítógépet (megj.: már voltak korábban is számítógépek, pl. a német Konrad Zusé-é a 30-as években, de ezt most már hagyjuk így), és Alan Turing kifejlesztette az első szoftvert. A mesterséges neurális hálózatok, a mesterséges intelligencia legjelentősebb alszegmense, egy statisztikai megközelítés, amelyet előrejelzési modellek fejlesztésére hoztak létre. A mesterséges neurális hálózatok az emberi agy tervezéséhez hasonló feldolgozó eszközökből és adatfeldolgozásból állnak. (Blackard & Dean, 1999)

A neurális hálóval történő vizsgálat során többféle beállítást alkalmazok, bővíttem vagy elveszek belőle, ezzel is karcsúsítva az eredményt, aszerint, hogy minél pontosabb, minél hatékonyabban becsülje meg a jövőbeli változásokat. Első körben az árfolyam százalékos változásaira koncentrálok, vagyis a cikkek tartalma alapján mekkora valószínűséggel tudom megmondani, hogy a következő napi árfolyamváltozás milyen irányú és mekkora nagyságú lesz.

Két különböző módszert alkalmaztam. Az első esetben minden egyes dátumot és árfolyamváltozást figyelembe vettem. A második esetben csak azokat, amik elértek egy bizonyos indikátorváltozót. Adott indikátorszavak előfordulását számoltam a cikkekben és csak akkor vettem validnak és vizsgáltam tovább a cikket, ha adott darabszámban előfordult. Ellenkező esetben nem vettem figyelembe, átugrottam a cikket és nem elemeztem. Vizsgálva azt, illetve elkerülve a kevés cikk szavak torzító hatását és nem árfolyam, hanem cikk oldalról vizsgálva csak.

A cikkek esetében indikátor és kulcsszavakat használok. Az indikátorszavak jelen esetben olyan szavak, amelyek előfordulásával valószínűsítem, hogy a cikk témája olaj árral kapcsolatos, így javasolt további vizsgálatra. Kulcsszavak azok a szavak, amelyeknek a mennyiségi előfordulását vizsgálom a cikkekben, az előfordulási gyakoriságukból és a korábbi árfolyamváltozások között keresek kapcsolatot, ami mintát adhat a jövőbeli változásokra. A szavak összeállítása saját választáson alapul, mind árfolyam emelkedésre, mind politikai befolyásolásra, termelési szavakra vonatkozik. Az ANN menet közben súlyozza, hogy pontosan melyikre mekkora szükség van,

mennyire vegye figyelembe. Valamint a több változat futtatása miatt a hasznosság és a végső formula tervek szerint kialakul.

Valamint a neurális háló esetében a kutatás során folyamatosan új módszereket és változatokat alkalmazok, úgy, mint neurális háló, visszacsatolt neurális hálóval történő mélytanulási módszer, tőzsdei mozgóátlag bevezetése a neurális háló bemeneti oldalába, hangulatelemzés, cikkek mesterséges összefoglalása. Vizsgálom, hogy az egyes bővítések és módosítások hogyan növelik a hatékonyságot, illetve melyik az a változat, amely leghatékonyabban tud működni, illetve mennyivel hatékonyabb egyéb más előrejelzéseknél.

### 3. Eredmények

Első körben törlés nélküli modellt alkalmaztam, vagyis amikor elemeztem azokat a napokat is, ahol olajárfolyamváltozás volt, de a cikkek között nem volt elég indikátor, hogy olajjal kapcsolatos cikket feltételezzem. Vagyis minden kulcsszó 0 darabszámmal lett kalkulálva.

A vizsgálat további részénél lefuttattam olyan elemzést, melyben kitöröltem azokat a napokat, melyeknél nem volt meg a kellő indikátorszám. Vagyis azt a hipotézist ellenőriztem, hogy a megfelelő adat nélküli napok félrevezetőek lehetnek, így ignoráltam őket. Ebben az esetben a napok egy jelentős része kiesik, így a ANN-re ható fehér zaj, pontosabban a nagy változások, de kulcsszó nélküli lefutások minimumra vannak redukálva, ezzel is elősegítve a lehető legtisztább elemzést. A későbbiekben szükséges vizsgálni, hogy így mennyiségileg mennyi vizsgálható, úgyszólván elegendő mennyiségű vizsgált napunk marad-e.

Az így kapott eredményekből egyértelműen látszik, hogy a modell jelenlegi fejlettségével és beállításával pontos eredményekre nem képes. Vagyis a következő napi árfolyamot csak elnagyolt becsléssel, nagy hibával tudja meghatározni. Fontos tisztázni, hogy mit értünk pontos becslés alatt. Amennyiben elfogadjuk a következő árfolyamváltozás esetében az 1,2%-on belüli eltérést, illetve pontosságot, úgy a modell az esetek ~45%-ban helyesen kalkulált. Ami nem feltétlenül mondható rossznak.

Emellett a SIGN (előjel előrejelzés) hatékonyság, vagyis a következő napi árfolyamváltozás előjelének (irányának) meghatározása 60% körüli pontossággal funkcionál, ami egyértelműen jelzi, hogy van kapcsolat a cikkek és az árfolyamelőrejelzés között. A vizsgált időszakban az árfolyam 51,77%-ban emelkedett. Az emelkedési többlet indokolt az inflációt figyelembevéve. Mindazonáltal, ha azt mondjuk, hogy az árfolyam másnap emelkedni fog, versus a neurális háló SIGN eredményei, a modell hatékonyabban mutatja ki a következő napi árfolyamot.

A következő vizsgálatban lefutattam egy RNN, vagyis visszacsatolt neurális hálózatot. Első körben csak az egy napos árat becsültem meg, majd később a változást is. Illetve az így kapott eredményeket visszahelyeztem a módosított törlés nélküli ANN-be. Valamint vizsgáltam annak lehetőségét, hogy a 12, valamint 26 napos mozgóátlag, vagyis az MACD, így a Signal mekkora mértékben növeli vagy csökkenti a hatékonyságot.

Vagyis egy dupla neurális hálót alkalmaztam az eredmények javítása érdekében. Ez már egy összetettebb Deep Learning, vagyis mélytanulási módszer. Az eredeti ANN layer számai alapján már mélytanulós módszerről beszélhetünk, ezen bővítés következtében egy bonyolultabb deep learning method jön létre, neurális háló eredményeket ágyazunk a neurális hálóba.

A hatékonyság bizonyos esetekben javult, bizonyos esetekben viszont nem. Jelenleg nem tudjuk kimondani, hogy az idősoros elemzés növeli vagy csökkenti a hatékonyságot. Egyelőre azt tudom megfogalmazni, hogy érdemi változást sem pozitív, sem negatív irányba nem mutat.

Mindamellet fontos megjegyezni, hogy jelenleg a tiszta árakból igyekeztem előrejelezni, semmiféle tőzsdei elemzést nem vizsgáltunk, mint a korábban kifejtett MACD elemzés. Kérdés, hogy ez adott esetben növeli a hatékonyságot vagy érdemben nem tud módosítani.

Az első verzióban a teljes cikkben kerestem, illetve vizsgáltam a szócikkeket. Második beállításként összefoglaltam a cikkeket és azokon belül vizsgáltam a kulcsszavakat. Vizsgálva azt, hogy a tömbösítés, lényegkiemelés növeli-e a hatékonyságot. Így koncentrálódik a mondanivaló, vélhetően csökken a szókinccs, ami növeli a releváns szavak előfordulását, így a teljes elemzést.

Az eredmények vizsgálata alapján egyértelműen látszik, hogy a modell érzékenységét nagy mértékben növeli az, hogy nem a teljes cikket, hanem csak egy kivonatot elemzünk. Vagyis, így a cikkek „koncentrációja” növeli a kulcsszó kutatási hatékonyságot.

Deklarálhatjuk, hogy a folytatólagos vizsgálatok során szükséges a cikkek kivonatát tovább vizsgálni a későbbi fejlesztési és hatékonyságnövelési tesztek során.

A kulcsszavak elemzésének kiegészítéseként a cikkek hangulati, avagy sentiment elemzését is elvégeztük az Nltk VADER lexicon segítségével. A hangulat elemzés olyan eljárás, amelynek segítségével az írásos szövegek, általában médiában megjelenő cikkek, hozzászólások vagy tweetek, lelkiállapotát, érzelmeit és véleményét tudjuk megállapítani. Az Nltk (Natural Language Toolkit) egy Python nyelven íródott könyvtár, amely számos eszközt és angol nyelvű korpuszt tartalmaz a számítógépes nyelvészeti kutatásokhoz. Az Nltk rendelkezik olyan eszközökkel, mint a tokenizálás, lemmatizálás és a stop word-ök eltávolítása, amelyek segítségével tisztíthatjuk az adatokat, hogy könnyebben kezelhetők legyenek az elemzések során. A VADER (Valence

Aware Dictionary and sEntiment Reasoner) lexicon egy kifejezetten közösségi média tartalmak hangulati elemzésére kifejlesztett eszköz.

A hangulatelemzéssel való bővítés egyértelműen hatékonyság növekedést eredményezett. Habár az eredmények összességében csak kismértékű növekedést eredményeztek, de egyértelműen hatékonyabbnak mondhatók. Érdekes megfigyelni, hogy 1 indikátorszám esetében jelentősen jobbak az eredmények, valamint 2 indikátorszám esetében is. Három indikátor esetében a korábbi elemzés valamivel hatékonyabb, majd mindkét módszer pontosan ugyanazokat az eredményeket preferálja az indikátorszám növelésével. Viszont, mivel a kevesebb indikátorszám, vagyis a több elemzett cikk eseménysorozatát jobban preferáljuk, így a kevesebb indikátorszám esetében lévő hatékonyságnövekedést mindig hasznosabbnak tekintjük.

Az eddigi neurális hálót bővíttem a tőzsdei árfolyamelemzésben használt MACD módszerrel. Ezt korábban már részleteztem. Röviden az MACD egy 12 és 26 napos mozgóátlag változásainak, keresztezéseinek figyelése, ami jó eséllyel jelzi a jelenlegi trendet, tehát az emelkedő vagy csökkenő trendet.

A neurális hálót folyamatosan bővítettem, minden egyes plusz bevitt releváns adathalmaz kisebb-nagyobb mértékben növelte a hatékonyságot.

A Sign érték közel 75%-os hatékonysággal működik, ami szerint 4 napból 3 esetben meg tudom mondani, hogy a következő napi árfolyam emelkedni vagy csökkenni fog. Ami elfogadható eredménynek számít.

A leghatékonyabb eredmények összességében 4 indikátorszámnál lefelé. Ez hatékonynak tűnik, hiszen a cikkek relatíve kevés részét fogja invalidnak nézni. Egészen pontosan kevés olyan cikket nem fog figyelembe venni, amit kellett volna, tehát a releváns cikkek döntő hányadát feldolgozza.

Mindenképpen szükséges vizsgálni azt, hogy milyen hatékonysággal működött volna a neurális háló abban az esetben, ha csak árfolyamalapú adatokkal dolgozunk, így kideríthető, hogy jelent-e, illetve mekkora pluszt jelent a kulcsszó kutatáson alapuló neurális háló. Pontosabban, érdemes-e ANN-t alkalmazni, vagy ugyanolyan vagy még jobb hatékonyság érhető el, ha csak matematikai modellt alkalmaznánk.

Így a kulcsszó kutatás validitását, illetve erősségét vizsgálva lefutattam a neurális hálót a kulcsszó kutatás nélkül, vagyis csak az olajárfolyam változásaiból kinyerhető számszerű adatokat vizsgáltam. Ezt mutatja be az 1. táblázat Árfolyam elemzésen alapuló neurális háló előrejelzés eredményei



<b>ELFOGADOTT MAXIMÁLIS ABSZOLÚT ELTÉRÉS</b>	<b>SIKERES BECSLÉS</b>
0,02	0,91%
0,04	1,52%
0,07	2,86%
0,1	3,65%
0,15	6,27%
0,25	10,28%
0,4	16,67%
0,8	34,06%
1,2	48,30%
1,6	61,25%
2	70,13%
2,5	77,37%
3	84,49%
3,5	88,69%
4	91,91%
SIGN	73,97%

1. táblázat Árfolyam elemzésen alapuló neurális háló előrejelzés eredményei

ELFOGADOTT MAXIMÁLIS ABSZOLÚT ELTÉRÉS	OIL MATH	SIKERES BECSLÉS NAP: t, IND: 4	ANN ind: 4 - OIL MATH különbség		ANN Best Value	ANN Best Value - OIL MATH különbség	
<b>0,02</b>	0,91%	0,48%	-0,43%	-47,25%	1,13%	0,22%	24,18%
<b>0,04</b>	1,52%	1,40%	-0,12%	-7,89%	1,92%	0,40%	26,32%
<b>0,07</b>	2,86%	3,32%	0,46%	16,08%	3,32%	0,46%	16,08%
<b>0,1</b>	3,65%	4,80%	1,15%	31,51%	4,80%	1,15%	31,51%
<b>0,15</b>	6,27%	7,03%	0,76%	12,12%	7,03%	0,76%	12,12%
<b>0,25</b>	10,28%	11,52%	1,24%	12,06%	11,52%	1,24%	12,06%
<b>0,4</b>	16,67%	18,33%	1,66%	9,96%	18,46%	1,79%	10,74%
<b>0,8</b>	34,06%	36,67%	2,61%	7,66%	36,67%	2,61%	7,66%
<b>1,2</b>	48,30%	50,50%	2,20%	4,55%	50,50%	2,20%	4,55%
<b>1,6</b>	61,25%	61,02%	-0,23%	-0,38%	61,59%	0,34%	0,56%
<b>2</b>	70,13%	70,01%	-0,12%	-0,17%	71,06%	0,93%	1,33%
<b>2,5</b>	77,37%	78,52%	1,15%	1,49%	79,18%	1,81%	2,34%
<b>3</b>	84,49%	84,59%	0,10%	0,12%	85,16%	0,67%	0,79%
<b>3,5</b>	88,69%	89,13%	0,44%	0,50%	90,22%	1,53%	1,73%
<b>4</b>	91,91%	91,84%	-0,07%	-0,08%	93,06%	1,15%	1,25%
<b>SIGN</b>	73,97%	72,94%	-1,03%	-1,39%	73,29%	-0,68%	-0,92%

2. táblázat ANN leghatékonyabb eredményeinek és csak olajárfolyamon alapuló

A 2. táblázat ANN leghatékonyabb eredményeinek és csak olajárfolyamon alapuló jól mutatja az eltéréseket, illetve a valódi különbségeket. A vizsgált hatékonyság az eddig megszokottak szerint az elfogadott maximális eltérés, vagyis az előrejelzett eredmények hány százaléka van a tényleges eredmények esetében a meghatározott hibahatáron belül. Az OIL MATH oszlop a csak olajárfolyam napi zárásainak neurális hálóval történő idősoros elemzéséből előrevetített eredmények pontossága. A korábbi fejezetekben tárgyaltak szerint a 4 indikátorszámos elemzést vettem legérvényesebbnek. Ezen túl csak kismértékben nő a hatékonyság, illetve ennyi indikátor alkalmazásánál nem esik ki túl sok cikk. Túl magas indikátorszám alkalmazásánál fennáll a veszély, hogy túl sok releváns cikket nem veszünk figyelembe. Ezt követő két oszlop a számszerű eltérés a kulcsszókutatáson alapuló ANN javára, illetve az ANN bázisához viszonyított eltérés. Ezt követően minden kulcsszókutatásos ANN esetében kiválasztottam soronként a legjobb eredményt, majd a korábbi módszerrel összehasonlítottam az olajáron alapuló Neurális Háló eredményeivel.

Az idősorok szinkronitásának elemzése napjainkban egyre inkább előtérbe kerül a tudományos kutatásokban, mivel számos interdiszciplináris területen alkalmazható, mint például a gazdaságtan, a meteorológia, a biológia

vagy akár a társadalomtudományok (Brockwell & Davis, 2016). Ebben a rövid összefoglalóban négy fő módszert mutatunk be, amelyeket az idősorok szinkronitásának elemzésére használnak: a Pearson korrelációt, az időkéleltetett keresztkorrelációt, a dinamikus idővetemítést, az azonnali fázisszinkront, a Wilmott-féle egyezési indexet és a  $R^2$  mutatót.

A Pearson korreláció eredményei szerint kimutatható bizonyos összefüggés. A 0,115-ös  $r$  érték azt jelenti, hogy a két változó között van egy gyenge pozitív lineáris összefüggés. Más szóval, a két változó közötti kapcsolat nem erős, de amikor az egyik változó értéke növekszik, a másik változó értéke is valamelyest növekedni fog. Azonban ez az összefüggés nem elég erős ahhoz, hogy határozott következtetéseket vonjunk le a két változó közötti kapcsolatról, és lehet, hogy más tényezők is befolyásolják a változók viselkedését.

Az időkéleltetett keresztkorreláció során (TLCC) eredménye 0,12. Azonban a 0,12-es érték továbbra is gyenge pozitív összefüggésre utal. Ez azt jelenti, hogy a két idősor közötti kapcsolat nem erős, de még mindig van némi összefüggés a két idősor között.

A Dinamikus idővetemítés (DTW) eredménye 3219,41. Ha a DTW eredménye 3219,41, az azt jelenti, hogy a két idősor között van némi eltérés, és a hasonlóságuk nem teljesen magas. A kapott érték arra utal, hogy az idősorok alakja, mintázata vagy viselkedése eltér egymástól, de nem olyan mértékben, mint amikor a DTW érték nagyon magas.

Az azonnali fázisszinkron (IPS) vizsgálatánál az eredmény azt mutatja, hogy a neurális háló hatékonyan előrejelzi az olajár változásokat, és magas fokú szinkronizációt ér el a valós adatokkal.

A Wilmott-féle egyezési index értéke 0,57, az arra utal, hogy az előrejelzési modell mérsékelt, de a gyakorlatban már viszonylag elfogadható pontosságú. Ez az érték azt jelzi, hogy a modell képes a valós adatok mintázatainak megragadására és viszonylag jól összehangolja az előrejelzéseket a tényleges megfigyelésekkel.

A 0,53-as  $R^2$  értékű modell azt jelzi, hogy a modell már hatékonyan képes megragadni az adatok mögötti mintázatokat, és az előrejelzései többnyire megbízhatók. Az eredmények alapján a modell már használható sok gyakorlati alkalmazásban, különösen olyanokban, ahol a magas fokú pontosság nem elengedhetetlen.

## 4. Következtetések és a javaslatok.

A kutatás során feltártam, hogy a neurális hálóval történő kulcsszó kutatás növeli a hatékonyságot az olajár előrejelzés terén, pontosabban hatékonyabb, mint a csak olajárváltozás idősoros és MACD adatokkal történő elemzése. Fontos megjegyezni, hogy a kizárólag árfolyamalapú előrejelzés során is duplikált neurális hálózatot alkalmaztam, vagyis RNN-nel jeleztem előre a várható értéket, illetve ezen felül még a várható értéket bővítettem egyéb MACD adatokkal és így egy második ANN-be került bele, amely ezek alapján jelezte az eredményt.

Az olajárváltozást vizsgálva kitűnik, hogy körülbelül ugyanakkora mértékben emelkedett, mint csökkent az ár a napi vizsgálat szerint. Tipikusan a napi árváltozása 0-1% közé esett. Vagyis az árfolyam volatilis, mindamellettt inkább emelkedő. Az esetek 54%-ban emelkedés volt tapasztalható.

Így pontosabban tudjuk értékelni a neurális hálóval előrejelzett eredményeket.

A neurális háló a leggyakoribb előfordulást szintén a 0 és 1 százalék közé rakta, viszont drasztikusan kevesebb szórással dolgozott. A neurális háló az esetek 58,9%-ban emelkedésre számított, ami nagyon hasonló, viszont csak az esetek körülbelül háromnegyedében sikerült eltalálni a változás helyes előjelét. Tulajdonképpen a kutatás leglényegesebb pontja, hogy a trendet képes volt az esetek nagy számában meghatározni, így felhasználói szemmel adott napokon elég nagy bizonyossággal tudtuk megállapítani, hogy épp emelkedő vagy csökkenő olajár trendben vagyunk, illetve meghatározni a trendfordulókat, ami fontos gazdasági döntések alapját képezheti.

Mindezek ellenére a Pearson korreláció, a TLCC, a DTW és kifejezetten az IPS eredményei kapcsán egyértelműsíthetjük, hogy az együttmozgás megvan. A Wilmott féle egyezési index, illetve az  $R^2$  csak megerősíti ezeket. Vagyis döntéselőkészítési szakaszra megfelelőek a neurális hálóval történő előrejelzések!

## 5. Új tudományos eredmények

A kutatás során azt vizsgáltam, hogy a spekulatív tőzsdei piac spekulatív jellege mennyire vizsgálható, vagyis mekkora hatással vannak rá bizonyos hírek és információk. A kutatás során egyértelműen kimutatható összefüggés a hírek tartalmainak elemzése és az azt követő árfolyamváltozások. Jelen kutatásban az olajár vonatkozásában vizsgáltam, de feltételezhetjük, hogy más esetekben is valid, illetve spekulációra szenzitívebb árfolyamok esetében még inkább hatékony lehet.

A nem bennfentes információkkal rendelkező vagy nem döntéshozásban résztvevő piaci szereplők is képesek nyílt információk alapján kikalkulálni, illetve következtetni bizonyos nyersanyagok árváltozásainak trendjeire, emelkedésére vagy csökkenésére, így azt beszámítva gazdasági döntéseikbe, amivel csökkenthetik a tőlük független kockázatot.

Jelen hírfolyamokban, illetve gazdasági szereplőket érintő információáramlásban rendkívül magas számban van zaj, ami torzítja a megértést. Vagyis szükséges speciális és nagyon szenzitív módon elemezni a híreket és információkat, illetve abból kiszűrni a lényeges és valóban hírértékkel rendelkező adatokat.

Képesek vagyunk gépi tanulási módszerekkel analitikus döntéseket hozni, vagyis valós emberek által írt hírek mondanivalóját, annak valóságtartalmát elemezni. Jelen módszernél sokkal kifinomultabb módszerekkel ez még hatékonyabbá tehető. Az kijelenthető, hogy automatizált módszerekkel is értelmezhető a nyomtatott sajtó. Ezáltal több száz cikk feldolgozható nagyon rövid idő alatt, amire emberként nem lennénk képesek.

Piaci szereplőként létezik olyan döntéshozatali függvény, mely a Wall Street Journal cikkei elemzésén alapszik és kellő bizonyossággal határozhatjuk meg az olajárfolyami trendet, illetve a következő időszak árfolyam emelkedésének vagy csökkenésének nagyságát.

Kijelenthetem, illetve megerősíthetjük, hogy a mesterséges neurális hálózatok képesek hatékony információfeldolgozásra, vagyis Big Data gyors és hatékony elemzésére is használhatóak.

Bizonyítottam, hogy a vizsgált folyóiratok és az árfolyam között összefüggés mutatható ki, vagyis egyértelmű a spekulációs árfolyammozgás az olajár tekintetében. A kapcsolat mértéke továbbra is kérdés, hiszen az előrejelzés

pontosságát illetően még lehetne pontosítani. Viszont az árfolyamot a cikkekben található kulcsszavak alapján határoztam meg, így kimutatható egyértelmű kapcsolat.

Kijelenthetem továbbá, hogy a Wall Street Journal (WSJ) újságcikkek tartalmának mesterséges neurális hálóval (ANN) történő elemzésével kellő pontossággal meghatározható a következő napi olajár változás.

Az optimalizálási és sebességnövelő algoritmusok alkalmazása során igazoltam, hogy az újságcikkek összefoglalásával, vagyis tömörítésével nagymértékben növelhető a mesterséges neurális hálóval történő előrejelzési hatékonyság.

Szintén bizonyítást nyert, hogy az újságcikkek hangulatelemzésével nagymértékben növelhető a mesterséges neurális hálóval történő előrejelzési hatékonyság.

A kutatás során vizsgáltam, hogy, amikor az olajárfolyam visszacsatolt neurális hálóval (RNN) történő vizsgálatával, tehát csak az árfolyam historikus mozgásának elemzésével kellő pontossággal meghatározható a következő napi olajár változás. Szintén igazolást nyert.

Az ANN működése során vizsgáltam, hogy mesterséges neurális háló rejtett rétegeinek és neuronjainak, vagyis háló részének nagymértékű növelésével jeletősen növelhető a hatékonyság. Jelen állítást fenntartásokkal tudom csak elfogadni, mivel a növelésével egy darabig exponenciálisan nőtt a hatékonyság, majd ezt követően már semmilyen javulást nem jelentett, így van egy felső hatékonysághatár adott feladat esetében.

Elemeztem, valamint össze is hasonlítottam és igazoltam, hogy a WSJ újságcikkeinek mesterséges neurális hálóval történő elemzése hatékonyabb, mint az árfolyam visszacsatolt neurális hálóval való elemzése, vagyis az árfolyam mozgásában nagyobb szerepe van a spekulációnak, mint a fundamentumoknak.

A kutatás során hipotézis volt, hogy a mesterséges neurális háló segítségével kapott előrejelzés hatékonyabb, mint adott matematikai-tőzsdei modellekkel történő árfolyamváltozás-előrejelzés. Jelen állítást teljes mértékben elfogadni nem áll módomban, hiszen az előrejelzés kellő pontossággal működött, viszont nem áll rendelkezésre elég anyag annak bizonyítására, hogy minden létező matematikai modellnél hatékonyabb. Így elképzelhető, hogy az állítás igaz.

## 6. A szerzőnek az értekezés témaköréhez kapcsolódó publikációi

### *Folyóiratcikk*

1. THALMEINER, G. – **BARTA, Á.** – GÁSPÁR, S. (2024): Extending the Hamiltonian operator with market information, *ECONOMICS & WORKING CAPITAL*
2. **BARTA, Á.** – MOLNÁR, M. (2023): Keyword research-based stock market oil price forecast validity test with neural network, *GRADUS 10: 1 Paper: 2023.1.ECO.008*, 9 p. (2023)
3. GÁSPÁR, S. - MUSINSZKI, Z. - HÁGEN, I.Z. - **BARTA, Á.** - BÁRCZI, J. - THALMEINER, G (2023): Developing a Controlling Model for Analyzing the Subjectivity of Enterprise Sustainability and Expert Group Judgments Using Fuzzy Triangular Membership Functions, *SUSTAINABILITY 15: 10 Paper: 7981*, 26 p. (2023)
4. GÁSPÁR, S. - PATAKI, L. - **BARTA, Á.** - THALMEINER, G - ZÉMAN, Z. (2023): Consumer Segmentation of Green financial Products Based on Sociodemographic Characteristics, *JOURNAL OF RISK AND FINANCIAL MANAGEMENT 16: 2 Paper: 98* , 19 p.
5. GÁSPÁR, S. - THALMEINER, G. - **BARTA, Á.** - ZÉMAN, Z. (2022): Development of a Fuzzy Controlling Model to Measure the Leanness of Manufacturing Systems, *ACTA POLYTECHNICA HUNGARICA 19: 4 pp. 189-207.*, 18 p.
6. THALMEINER, G. - GÁSPÁR, S. - **BARTA, Á.** - ZÉMAN, Z. (2022): Prediktív KPI-ok osztályozási módszerének ismerete, *CONTROLLER INFO X: 3 pp. 2-6.*, 5 p. (2022)
7. **BARTA, Á.** - MOLNÁR, M. (2021): Crude oil stock market trend reversal forecast based on Wall Street Journal articles with keyword indication, *GRADUS 8: 3 pp. 118-125.*, 8 p.
8. **BARTA, Á.** - MOLNÁR, M. (2021): Indication of organizational collusion by examining dynamic market indicators, *GRADUS 8: 1 pp. 160-165.*, 6 p.
9. **BARTA, Á.** - MOLNÁR, M. (2021): Forecasting oil price based on online occurrence volume, *MODERN SCIENCE / MODERNI VEDA № 1 - 2021 pp. 5-11.*, 7 p.
10. THALMEINER, G. - GÁSPÁR, S. - **BARTA, Á.** - ZÉMAN, Z. (2021): Application of Fuzzy Logic to Evaluate the Economic Impact of COVID-19: Case Study of a Project-Oriented Travel Agency, *SUSTAINABILITY 13: 17 Paper: 9602*, 19 p.

11. MOLNÁR, M. - **BARTA, Á.** - BÁN, E. - VILLÁNYI, J. (2019): A novel approach to market anomaly sensing using neural networks, *MECHANICAL ENGINEERING LETTERS: R AND D: RESEARCH AND DEVELOPMENT* 19 pp. 103-112., 10 p

*Konferenciakiadvány vagy konferenciaközlemény*

1. **BARTA, Á.** - MOLNÁR, M. - NAÁRNÉ TÓTH, ZS. (2023): Idősor szinkron validitás elemzés kulcsszókutatáson alapuló neurális háló által előrejelzett olajárfolyam változáson, *MULTIDISZCIPLINÁRIS KIHÍVÁSOK SOKSZÍNŰ VÁLASZOK*: 3 pp. 3-23., 21 p.
2. **BARTA, Á.** - NAÁRNÉ TÓTH, ZS. - MOLNÁR, M. (2023): Neurális háló alkalmazásával történő olajárfolyam előrejelzés eredményeinek idősor szinkron validitás elemzése / Time Series Synchronous Validity Analysis of the Results of Oil Exchange Forecasting using a Neural Network, In: Vágány, Judit; Fenyvesi, Éva (szerk.) *Multidiszciplináris kihívások, sokszínű válaszok*: 11. Tudományos Szimpózium: absztrakt füzet, Budapest, Magyarország: Budapesti Gazdasági Egyetem (BGE) (2023) pp. 52-53., 2 p.
3. MOLNÁR, M. - **BARTA, Á.** - VILLÁNYI, J. (2023): A piaci bizonytalanság becslése keresésintenzitás-alapú megközelítésben / Estimating Market Uncertainty using search volume indicators, In: Vágány, Judit; Fenyvesi, Éva (szerk.) *Multidiszciplináris kihívások, sokszínű válaszok*: 11. Tudományos Szimpózium: absztrakt füzet, Budapest, Magyarország: Budapesti Gazdasági Egyetem (BGE) (2023) pp. 54-55., 2 p.
4. **BARTA, Á.** - MOLNÁR, M. - NAÁRNÉ TÓTH, ZS. (2022): Investigation of the Online Press and Commodity Exchange Using Neural Networks, In: [S., n.] (szerk.) *Strategic Management Proceedings: 27th International Scientific Conference and Decision Support Systems in Strategic Management*, Subotica, Szerbia: University of Novi Sad, Faculty of Economics in Subotica (2022) 518 p. pp. 337-342., 6 p.
5. MOLNÁR, M. - **BARTA, Á.** (2021): Global market collusion analysis using artificial neural networks, In: Kinga, Pázmándi; Kinga, Pétervári (szerk.) *Space – Time – Market– Economy*, Budapest, Magyarország: HVG-ORAC (2021) 395 p. pp. 295-307., 13 p.
6. **BARTA, Á.** (2021): Tőzsdei trendfordulók előrejelzése pénzügyi folyóiratokban történő kulcsszókutatással, *AGTECO 2021*
7. **BARTA, Á.** - MOLNÁR, M. (2020): Piactorzító hatások elemzése a gépi tanulás eszközeivel, In: Horváth, Bálint; Kápolnai, Zsombor; Földi, Péter (szerk.) *Közgazdász Doktoranduszok és Kutatók VI. Nemzetközi Téli*



Konferenciája: Konferenciakötet, Budapest, Magyarország: Doktoranduszok Országos Szövetsége (DOSZ) (2020) 373 p. pp. 32-40., 9 p.

8. **BARTA, Á.** (2020): Kartellműködés kimutatás piaci dinamizmusok alapján neurális hálók alkalmazásával, AGTEDU 2020
9. **BARTA, Á.** (2020): Indication of cartel activity using neural networks, In: Horváth, Bálint; Földi, Péter; Kápolnai, Zsombor (szerk.) VI. Winter Conference of Economics PhD Students and Researchers: Book of Abstracts, Gödöllő, Magyarország: Szent István University, Doktoranduszok Országos Szövetsége, Közgazdaságtudományi Osztály (2020) 128 p. pp. 21-21., 1 p.

## 7. Irodalomjegyzék

- Arshad, S., Rizvi, S. A., Haroon, O., Mehmood, F., & Gong, Q. (2021). Are oil prices efficient? *Economic Modelling*, Vol. 96., 362-370. doi:10.1016/j.econmod.2020.03.018
- Blackard, J. A., & Dean, D. (1999). Comparative Accuracies of Artificial Neural Networks and Discriminant Analysis in Predicting Forest Cover Types From Cartographic Variables. *Computers and Electronics in Agriculture Vol 24 Issue 3*, 131-151.
- Brockwell, P. J., & Davis, R. A. (2016). *Introduction to Time Series and Forecasting*. Springer. doi:10.1007/978-3-319-29854-2
- Fattouh, B., Kilian, L., & Mahadeva, L. (2013). The role of speculation in oil markets: what have we learned so far. *Energy Journal Vol 34 Issue 3*, 7-33.
- Hamilton, J. D. (2008). Understanding crude oil prices. *NBER Working Paper No. 14492*.
- IEA. (2020). *Global Energy Review 2020*. Forrás: <https://www.iea.org/reports/global-energy-review-2020>
- Jain, A. K., Mohiuddin, K. M., & Mao, J. (1996). Artificial neural networks: a. *Computer Vol. 29. Issue 3.*, 31-44.
- Jiang, M., An, H., Jia, X., & Sun, X. (2017). The influence of global benchmark oil prices on the regional oil spot. *Energy, Vol. 118, 1.*, 742-752. doi:10.1016/j.energy.2016.10.104
- Kaufmann, R. K. (2011). The role of market fundamentals and speculation in recent price changes for crude oil. *Energy Policy Vol 39*, 105-115.
- Kilian, L. (2009). Not all oil price shocks are alike: disentangling demand and supply shocks in the crude oil market. *American Economic Review Vol 99 Issue 3*, 1053-1069.
- Kutsurelis, J. (1998). *Forecasting Financial Markets Using Neural Networks: An Analysis Of Methods And Accuracy, Thesis*. Naval Postgraduate School Monterey: California.
- Xin, Y. (1999). Evolving artificial neural networks. *Proceedings of the IEEE, vol. 87, no. 9.*, 1423-1447. doi:10.1109/5.784219