

OTDK-dolgozat

2025

**MNB INTÉZET - NEUMANN JÁNOS EGYETEM
GAZDASÁGTUDOMÁNYI KAR**



AZ NBA DÖNTŐK HATÁSA A RÉSZVÉNYPIACRA

THE NBA FINALS' EFFECT ON THE STOCK MARKET

Fövényi Zsombor

Konzulens: Petróczy Dóra Gréta

Kézirat lezárásának dátuma: 2024. 04. 15.

Tartalomjegyzék

Absztrakt	4
Bevezetés.....	5
1. Irodalmi áttekintés.....	7
1.1. A várakozási hatás, az agyi aktivitás, az érzelmi tapasztalat és a döntések kapcsolata...	7
1.2. A hangulat a döntések és a befektetők kapcsolata	10
1.3. A sportesemények és az érzelmi állapot kapcsolata	15
1.4. A sportesemények és a részvényhozamok kapcsolata	16
2. Adatok és módszertan.....	17
2.1. Adatok.....	17
2.2. Módszertan	18
3. Eredmények.....	23
3.1. Eredmények limitációi és további vizsgálatok lehetőségei	24
4. Összefoglalás.....	26
Irodalomjegyzék.....	27
Melléklet.....	29

Ábrajegyzék

1. ábra Affective circumplex	7
2. ábra Monetary Incentive Delay feladat folyamata	9
3. ábra Az eseményelemzés elemei	18
4. ábra A Kummulált átlagos abnormális hozamok alakulása.....	23

Táblázatjegyzék

1. táblázat Az NBA döntők időpontjai, döntőben szereplő államok és az adott eseményhez felhasznált vállalatok száma	18
2. Táblázat A kummulált átlagos abnormális hozamok és a hozzájuk tartozó T-próbák	24

ABSZTRAKT

Tanulmányomban az NBA döntők (amerikai Nemzeti Kosárlabda bajnokság) mérkőzéseinek részvényhozamokra mért hatásait vizsgáltam. A hipotézisemet miszerint a hatás megfigyelhető, eseményelemzés során Fama és French három faktoros modelljének segítségével vizsgáltam meg. Reprezentatív mintával dolgoztam, minden NYSE, Nasdaq, NYSE Mkt és NYSE Arca részvénytőzsián megtalálható részvényt felhasználtam az elemzés során 2011 és 2023 között. A hatás nem bizonyult szignifikánsnak, amely cáfolta a kiinduló hipotézisemet. Az hatás létezésének teljes kizárásához további kutatások szükségesek, amelyek lehetőségeit a tanulmány során kifejtem.

BEVEZETÉS

A jövőbeli részvényhozamok pontos előrejelzése nem lehetséges. Vannak azonban olyan események, amelyek bizonyos időközönként ismétlődnek és hatással lehetnek a részvényhozamokra. A tanulmány során a sportesemények hatásaival foglalkozom, azon belül is az NBA (National Basketball Association), azaz az amerikai Nemzeti Kosárlabda Liga döntő mérkőzéseinek, részvénytőzsiacra kifejtett hatásaival. Számos tanulmány vizsgálja a sportesemények részvénytőzsiacra mért hatásait (Payne és szerzőtársai, 2018; Galoppo és Boido, 2020; Fan és Wang, 2018). A nagyobb, széles köröket megmozgató sportesemények vizsgálatával egy pontosabb képet kaphatunk arról, hogy az adott esemény milyen hatással van az azzal területi-, gazdasági vagy más módon kapcsolatban álló részvények hozamaira. Az intuíción a sportesemények és a részvényhozamok kapcsolata között, hogy a sportesemények fokozott érzelmi állapotot idéznek elő a szurkolókban (Knoll és szerzőtársai, 2014), a befektetők döntéseit pedig jelentősen befolyásolja az érzelmi állapotuk (Knutson és Greer, 2008). Megfelelően nagy mértékű nézettség esetén a sportesemény így befolyásolni tudja a részvényhozamokat (Payne és szerzőtársai, 2018). A hatást az is erősíti, hogy az emberek hangulata jelentős mértékben függ attól, hogy a hozzájuk közel állók milyen hangulatban vannak (Block és Burnett, 2022). Azoknak a hangulatára is hatással lehet tehát egy sportesemény, akik közvetlenül nem kötődnek hozzá. Ezek a hatások feltehetően erőteljesebben jelennek meg a kis tőkeértékű részvények esetében (Payne és szerzőtársai, 2018).

Kutatási kérdésem, hogy van-e hatása az NBA (National Basketball Association), vagyis az amerikai Nemzeti Kosárlabda Liga döntő mérkőzéseinek, a részvényhozamokra. Hipotéziseim, hogy (i.) a hatás megfigyelhető és (ii.) nem csak reakciós, hanem várakozási hatást (mérkőzések előtt is befolyásolja a részvényhozamok alakulását) is kivált az esemény. Az elemzésem során a 2011 és 2023 között játszott NBA döntők csapatainak államaiban bejegyzett székhellyel rendelkező vállalatokat gyűjtöm össze. Majd azt vizsgálom meg, hogy van-e hatása a döntők mérkőzéseinek ezeknek a vállalatoknak a részvényhozamaira. A kutatásom cáfolja az előzetes hipotézisemet, a hatás nem kimutatható.

Az NBA döntők részvénytőzsiacra mért hatásairól előzetes kutatómunkám során nem találtam példát. Kutatásomban Payne és szerzőtársai (2018) tanulmányából indulok ki, amelyben az NFL (National Football League), vagyis az amerikai Nemzeti Futball Liga döntőinek részvényhozamokra mért hatásait figyelték meg. Számos eltérés nehezíti azonban az NBA döntők hatásainak kimutatását, melyeket a későbbiekben részletesen is kifejtek. A fő nehézség

azonban a kisebb nézettségéből fakad, amely gyengébb hatás feltételezésére ad okot. Kisebb nézettségű ugyan, mint az NFL, viszont a második legnézettebb amerikai sportág (statista.com), egyre bővülő piaccal, ezért érdemes megvizsgálni a hatásait.

Eseményelemzés során vizsgálom meg az NBA döntők mérkőzéseinek hatásait. A döntőben szereplő csapatok államaiban székhellyel rendelkező, tőzsdén jegyzett vállalatok részvényhozamait veszem alapul. Ez a területi meghatározás azon feltevésen alapszik, hogy az Amerikai Egyesült Államok lakosai alapvetően államok szintjén határozzák meg hovatartozásukat és így egy sporteseménynek is az abban résztvevő államok lakosaira van a legnagyobb érzelmi hatása.

1. IRODALMI ÁTTEKINTÉS


A kutatásomhoz kapcsolódó irodalmakat a következő szisztémában mutatom be. Először a várakozás döntésekre- és ezáltal a befektetők döntéseire kifejtett hatásaival foglalkozom. Majd azzal, mitől függ egy egyén hangulata, érzelmi állapota, valamint az miként befolyásolja a döntéseit, ebből fakadóan pedig a befektetők döntéseit is. Ezután kifejtem milyen hatása van a sportnak a szurkolók érzelmi állapotára. Végül pedig a sportesemények és a részvényhozamok közötti kapcsolatokat ismertetem átfogó irodalmi elemzés során.

1.1. A várakozási hatás, az agyi aktivitás, az érzelmi tapasztalat és a döntések kapcsolata

A 'várakozási hatás', olyan érzelmi állapotra utal, amelyet az emberek akkor tapasztalnak, amikor valamilyen, számukra jelentős kimenetelű eseményt várnak (Knutson és Greer, 2008).

A kísérleti pszichológia ősatyja Willhem Wundt egy többdimenziós keretrendszert hozott létre, amelyekkel az érzelmi tapasztalást jellemezte. Az azokat kiváltó hatásról pedig azt gondolta, hogy az agyból indul ki. A három dimenzió Wundt szerint a következő skálakon mozog (i) élvezetes és kellemetlen, (ii) fokozó és tompító, és (iii) feszült és nyugtató (Knutson és Greer, 2008). A 20. században számos tanulmány alátámasztotta Wundt elméletét (Osgood et al. 1957; Russell 1980; Watson & Tellegen 1985), melyek Wundt alapján egy horizontális 'valence' és egy vertikális 'arousal' dimenzióval kör alapú skálarendszert hoztak létre. Ezt kiegészítették egy-egy 45 fokos fordulat segítségével megkülönböztetett negatív- és pozitív 'arousal' dimenziókkal. Az így létrehozott, érzelmi tapasztalatot meghatározó, kétdimenziós

1. ábra Affective circumplex



kör alapú skálarendszert (affective circumplex) az 1. ábra mutatja (Knutson és Greer, 2008). A horizontális valence dimenzió a boldogságnak a skálája, amely balról jobbra halad. A vertikális


arousal dimenzió alsó felén alul- míg a felső végén túlfűtött érzelmi állapot helyezkedik el. A 45 fokos elforgatással megkülönböztetett pozitív és negatív arousal rendre a fáradtságtól az izgatottságig és a nyugottságtól a félelemig fut.

Az agy különböző területeinek aktiválódása eltérő érzelmi tapasztalathoz vezet, amely befolyásolhatja az egyén döntéseit is (Knutson és Greer, 2008). A tapasztalt érzelmek eltérő reakciót válthatnak ki belőlük. Az emlősök olyan agyi területeinek elektromos stimulációja, amelyek a midbrain dopamine neurons vetületei, amely a nucleus accumbens-t (NAcc) is tartalmazza, valamint a medio-prefrontális kérget (MPFC), közeledő viselkedést válthatnak ki. Mind az Nacc, mind pedig az MPFC aktivitás szoros kapcsolatot mutat a pozitív arousal tapasztalásával. Más agyi területek, amelyek az anterior insula-tól és a basolateral amygdalától, a stria terminalis-on keresztül ereszkednek le a medial hypothalamus-hoz és a periaqueductal grey-hez pedig elkerülő viselkedést. Az anterior insula aktivitása pedig kapcsolatban áll mind a pozitív, mind a negatív arousal érzelmi tapasztalattal (Knutson és Greer, 2008).

Az fMRI (functional magnetic resonance imaging) technológia fejlődésével lehetségessé vált az agy területi aktivitásainak leképezése. A technológia segítségével a kutatók vizualizálni tudják az oxigén mértékének változását a véráramban, amely 4-6 másodperccel az idegrendszeri aktivitásban bekövetkező változás után jön létre (Grosenick és szerzőtársai, 2008). Számos tanulmány vizsgálja (Knutson és Greer, 2008; Knutson és szerzőtársai, 2008c; Knutson és szerzőtársai, 2007), hogy különböző események hogyan befolyásolják az agy területeinek aktiválódását. Sok esetben az eseményt időben elválasztják várakozás és kimenetel szerint (Knutson és Greer, 2008; Knutson és szerzőtársai 2007; Grosenick és szerzőtársai, 2008). Knutson és Greer (2008) tanulmányukban pedig a várható és bekövetkező kimenetelt is, nyereség és veszteség szerint.

Knutson és Greer (2008) tanulmányukban meta-analízist készítettek azokról a kutatásokról, amelyek fMRI segítségével elemezték várakozási hatást (a kimenetel hatásával együttesen) az agyi aktivitásra. Az fMRI alapú kísérleteket a monetary incentive delay (MID), vagyis késleltetett pénzösztönző feladattal végezték el. A játék menete a 2. ábrán látható. A feladat lényege, hogy az alanyok először egy információt látnak arról, hogy lehetőségük van pénzt nyerni (várható nyereség), vagy elkerülni pénzvesztést (várható veszteség). Ezután egy célpont jelenik meg a képernyőn, ekkor egy gombot kell megnyomniuk mielőtt eltűnik, majd két másodperccel később láthatják az aktuális játék kimenetelét és a teljes összeget, amit addig gyűjtöttek (vagy vesztek).

2. ábra Monetary Incentive Delay feladat folyamata



A kutatások azt mutatták, hogy a várható nyereség esetén a várható veszteséghez képest nagyobb aktivitást mutatott az NAcc-ben. A várható nyereség a nyereséges kimenetelhez képest is nagyobb mértékű aktivitást mutatott az NAcc-ben, míg a nyereséges kimenetel a várható nyereséghez képest magasabb aktivitást mutatott az MPFC-ben. A várható veszteségnél pedig a várható nyereséghez képest magasabb aktivitás volt megfigyelhető az anterior insula egyes területeiben, illetve a medial caudate-ben. Az anterior insula bizonyos területeiben megnövekedett aktivitás volt megfigyelhető a várható nyereség esetén a várható veszteséghez képest, valamint fordított esetben az anterior insula más területeiben volt kimutatható a magasabb aktivitás. Ez azt mutatja, hogy az anterior insula-ban az aktivitás megnövekedik akkor is, ha a várható esemény kimenetele bizonytalan. A tanulmányok eredményei azt mutatják, hogy az NAcc-ben és az anterior insulában is növekedik az aktivitás mértéke, bizonytalan kimenetelű ösztönzőkre várakozásnál. Valamint az NAcc-ben az aktivitás növekedése a várható nyereség esetén a legjelentősebb (Knutson és Greer, 2008).

Knutson és Greer (2008) tanulmányában azt is megvizsgálták, hogy az 1. ábrán látható rendszer alapján milyen érzelmeket tapasztaltak a résztvevők a kísérlet folyamán. A tanulmányok azt mutatják, hogy az MID feladat elején felvillanó információ az ösztönző típusáról várakozási hatást fejt ki az alanyokban. A várakozási hatás pedig nagyobb hatást ért el náluk az érzelmi tapasztalat arousal dimenziójában, mint a kimenetel megismerése. Ez azt jelenti, hogy felfokozottabb hangulatba kerültek miközben a játékot és annak eredményét várták, mint amikor megtudták a játék kimenetelét. A várakozási hatásnak, a várható nyereség és a várható veszteség esetén is növelő hatása volt a résztvevők esetében az arousal dimenzióra.

A kimenetek megismerésének a valence dimenzióra jelentősebb hatása volt, mint az arousal dimenzióra. A kimenetek esetében, növekedett a valence, ha várható nyereségnél valóban nyereséget realizáltak a résztvevők vagy, ha várható veszteség esetén elkerülték a veszteséget. Ezzel szemben akkor csökkent a valence értéke, ha várható nyereség esetén végül nem sikerült megszerezniük azt vagy, ha várható veszteség esetén valóban veszteséges lett a játékuk kimenetele. Ezek az eredmények alátámasztják, hogy a várakozási hatás az agyi területek aktivitását, valamint az egyének érzelmi tapasztalatait is befolyásolja (Knutson és Greer, 2008).

Végül Knutson és Greer (2008) tanulmányukban összegezték, hogy a kutatások alapján a várakozási hatás hogyan befolyásolja az érzelmi tapasztalatot és az eltérő agyi aktivitáson keresztül az egyének döntéseit. Az eredmények alapján az NAcc-ben kimutatható magasabb aktivitás növeli az esélyét annak, hogy az egyén kíváncsún talál egy terméket és megvásárolja azt, valamint annak is, hogy magasabb kockázatú befektetési döntést hoz meg. Ezzel szemben az anterior insula-ban megfigyelhető magasabb aktivitás növeli az esélyét annak, hogy az egyén elkerüli a termék megvásárlását, mert túlrazottnak gondolja azt, valamint annak is, hogy alacsonyabb kockázatú befektetési döntést hoz meg. A döntésektől független, viszont az érzelmi tapasztalatra ható információk is befolyásolják a végső döntést, mivel hatással vannak az agy különböző területeinek aktivitására.

1.2. A hangulat a döntések és a befektetők kapcsolata

Az előző alfejezetben bemutattam a szakirodalmak alapján, hogy milyen hatással van az emberekre egy jelentős esemény várása, illetve az esemény kimenetelének megismerése. A kutatások azt mutatják, hogy a várakozási hatás és az esemény kimenetele is befolyásolja az emberek érzelmeit, a különböző agyi területeikben pedig eltérő mértékű aktivitását okoznak. Ez a két tényező pedig befolyásolja az emberek döntéseit, így pénzügyi döntéseiket is. Ebben az alfejezetben fejtem ki, hogy az egyes agyi területek eltérő aktivitása (amely korrelál az érzelmi tapasztalattal) hogyan befolyásolja az emberek döntéseit, amely hatással van pénzügyi befektetéseikre is. Az előző alfejezetben kifejtett pozitív arousalt a kutatások, az NAcc aktiválódásával indexálják, míg a negatív arousalt pedig az anterior insula aktiválódásával. A pozitív arousal az approach behaviour esélyét növeli, amíg a negatív arousal pedig az avoidance behaviour esélyét (Knutson és Greer, 2008).

Knutson és szerzőtársai (2008c) tanulmányukban azt vizsgálták, hogy valóban nagyobb értéket tulajdonítanak az emberek a tulajdonukban lévő tárgyaknak, mint azoknak, amelyek még nincsenek a birtokukban. A kutatásukban szintén fMRI technológiával vizsgálták a résztvevők agyi területeinek aktivitását. Az alanyoknak három különböző esetben kellett döntenie arról, hogy pénzt vagy terméket szeretnének. Az egyik a vásárlás volt, ahol el kellett dönteni, hogy a képernyőn felvillanó terméket meg szeretnék-e vásárolni a feltüntetett áron. Egy másik eset az eladást szimulálta, ahol még a feladat előtt megkapták az adott terméket és azt kellett eldönteniük, hogy megválnak-e tőle a feltüntetett összegért cserébe. A harmadik eset a választás volt, ahol el kellett dönteniük, hogy a terméket vagy a feltüntetett árral egyenértékű összeget szeretnék megtartani.

A kutatás eredményei kimutatták, hogy az NAcc aktivitásának mértéke korrelált azzal, hogy a résztvevő mennyire kedvelte az adott terméket, a vásárlás és az eladás esetén is. Azonban az NAcc aktivitásának mértékét nem befolyásolta, hogy vásárlásról, eladásról vagy választásról volt szó. Az MPFC aktivitása ezzel szemben negatívan korrelált az ár százalékos értékével vásárlás esetén, de pozitívan az eladás esetében. A vétel esetén az MPFC aktivitásának mértéke megnövekedett az alacsony árak hatására, viszont eladás esetén az alacsony árak hatására csökkent. Összességében is kimutatható volt, hogy az eladás esetében alacsonyabb volt az MPFC aktivitásának mértéke az árak hatására, mint a vételnél. Az NAcc és az MPFC aktivitásában tehát elkülönülő mintázatokat figyeltek meg. Ezek a mintázatok azt is alátámasztják, hogy a különböző agyi területek eltérő mértékű aktivitása, a nyereség megbecslését egymástól elkülönülő módon teszik lehetővé, az ösztönzők felmérésének különböző időpontjaiban. Az MPFC aktivitási mértékében megfigyelt különbségek az eladás és a vásárlás között, azt mutatják, hogy ez az agyi terület a szubjektív értéket segít nyomon követni, nem pedig az objektív mértékét az árak. Az MPFC aktivitásának mértéke a választás opciónál is magasabb volt az alacsony árak hatására, mint az eladásnál, annak ellenére, hogy ez a két ösztönző lényegében azonos. Ez kiváló példája a keretezési hatásnak, annak hogyan befolyásolhatja a feladat megfogalmazása az alany döntéseit (Knutson és szerzőtársai, 2008c).

Knutson és szerzőtársai (2007) tanulmányukban fMRI segítségével vizsgálták az különböző agyi területek aktivitásának és a döntések kapcsolatát. Knutson és szerzőtársai (2008c) tanulmányához hasonló keretek között, azonban csupán a vételi esetben figyelték meg az alanyok különböző agyi területeik aktivitásának és azt követő vásárlási döntéseiknek a kapcsolatát. A résztvevők egy terméket láthattak, majd kis idő múlva az árát, ezt követően pedig ki kellett választaniuk gombok segítségével, hogy megvásárolják az adott terméket vagy nem.

Az eredmények azt mutatták, hogy egy adott termék preferenciája és az NAcc-ben mért aktivitás között pozitív korreláció van. Ez a kapcsolat a termék megjelenítésénél (termék ideje) és később az ár megismerésénél (ár ideje) is megfigyelhető volt. Az ár, amelyet a résztvevő hajlandó fizetni a termékért és a valódi ár közötti különbség (ár differencia) korrelál az MPFC-ben mért aktivitással. Az MPFC és az ár differencia közti kapcsolat csak az ár ideje alatt volt megfigyelhető, előtte nem. Valamint az insula-ban mért aktivitás negatívan korrelált a vásárlással, a döntési időben. Mind a három agyi területben a megfigyelt aktivitás mértéke szignifikánsan hozzájárult a vásárlási döntés előrejelzéséhez. A bilaterális NAcc-ben mért aktivitás a termék ideje alatt, míg a bilaterális MPFC-ben mért aktivitás az ár ideje alatt segített előre jelezni az adott termék megvásárlását. A jobb insula esetében mért aktivitás pedig az ár ideje alatt segített előre jelezni az adott termék megvásárlásának elutasítását. Az agyi aktivitások segítségével a vásárlás előrejelzése 60%-ra növekedett, amely szignifikánsan magasabb a véletlenszerű 50%-os előrejelzésnél. Az eredmények alapján az elkülönülő agyi területekben mért aktivitások mértéke, várható nyereség és veszteség esetén eredményesen felhasználható a vásárlási döntések előrejelzésében (Knutson és szerzőtársai, 2007).

Grosenick és szerzőtársai (2008) fMRI technológiával vizsgálták a résztvevők agyi aktivitását szintén egy vételi feladattal, amely a SHOP (save holdings or purchase) elnevezést viseli. A résztvevők a teszt alatt óránként 20 000 dollárt kaptak a részvételért és további 40 000 dollárt a termékek vásárlására. A Knutson és szerzőtársai (2007) tanulmányában megismert feladat keretei között kellett döntéseket hozniuk arról, hogy a feltüntetett terméket megvásárolják vagy inkább a termék vásárlására fenntartott összeget tartják meg. Vásárlás esetén két héten belül szállították azokat ki nekik. A termékek kiskereskedelmi ára 8 és 80 000 dollár között volt, a feladatban ezek 25%-át tüntették fel, hogy ösztönözzék a vásárlást. A feladat során megvásárolható termékek ára így 2 és 20 000 dollár között helyezkedett el.

Más kutatásokhoz hasonlóan az NAcc-ben, az MPFC-ben és az insula-ban mért aktivitási szint változásainak segítségével jelezték előre, hogy az alany megvásárolja-e az adott terméket. A kutatás célja az volt, hogy felépítsék azt a statisztikai modellt, amelyik legpontosabban tudja kivitelezni az előrejelzést. Végül egy SPDA (sparse penalized discriminant analysis) modell, a PDA-ENET (penalized discriminant analysis – elastic net) modell segítségével 67%-os klasszifikációs rátát sikerült elérniük. Az NAcc-ben, MPFC-ben és insula-ban mért aktivitási szint alapján 67%-kal tudták előre jelezni, hogy az alany megvásárolja-e az adott terméket. Az előrejelzés pontossága szignifikánsan magasabb, mint a Knutson és szerzőtársai (2007) tanulmányában elért 60% és messze magasabb, mint a véletlenszerű előrejelzés 50%-os

pontossága (Grosenick és szerzőtársai, 2008). Az eredmény bemutatta, hogy az agyi területek aktivitásában megfigyelt változások jelentős előrejelző erővel bírnak az egyének vásárlási döntéseire.

Khunen és Knutson (2005) tanulmányukban fMRI segítségével vizsgálták az agyi aktivitás és a pénzügyi befektetések kapcsolatát. Kidolgoztak a vizsgálatához egy BIAS (behavioral investment allocation strategy) elnevezésű feladatot. A feladat során 20 különböző blokkban 10-10 körben kellett meghozniuk a befektetési döntéseiket a résztvevőknek. Két részvény és egy kötvény közül választhattak. A részvények közül minden blokkban az egyik volt a rossz, a másik pedig a jó részvény. A jó részvény magasabb várható kifizetést jelent. A kötvény kifizetése alacsony volt, viszont 100%-os valószínűség mellett. Minden körben választaniuk kellett egyet a három befektetés közül, majd minden kör végén láthatták az aktuális kör kifizetését, valamint a teljes játék kumulatív kifizetését is.

A kutatás eredményei azt mutatták, hogy a várakozási hatás során az NAcc-ben mért aktivitás szintje és az anterior insula-ban mért aktivitás szintje is meghatározó eleme volt az alanyok döntésének. Azonban az előző kör választása is jelentős befolyással bírt. A várakozási hatás során az NAcc-ben megnövekedett aktivitás csak abban az esetben növelte az esélyét egy részvény választásának, ha az alany az előző körben egy kötvényt választott. A várakozási hatás eredményeként, az anterior insula-ban megnövekedett aktivitás növelte a kötvény választásának az esélyét abban az esetben, ha előtte egy részvényt választott a résztvevő. Az MPFC-ben mért magasabb aktivitás viszont nem korrelált a résztvevő döntésével. A résztvevők döntéseit egy hipotetikus kockázatsemleges ügynök befektetési döntéseivel hasonlították össze. A magasabb aktivitás az NAcc-ben tehát megelőzte a kockázatkedvelő döntést, amely sok esetben kockázatkereső hibákhoz is vezetett. A magasabb aktivitás az anterior insula-ban pedig a kockázatkerülő befektetési döntést előzte meg, amely sok esetben kockázatkerülő hibákhoz vezetett (Khunen és Knutson, 2005).

Hampton és O'Doherty (2007) fMRI technológia segítségével vizsgálták, hogy melyek azok az agyi területek, amelyek aktivitása meghatározza az emberek döntéseit. A feladatban (amely közben fMRI technológiával mérték az agyi területek aktivitását) a résztvevőknek két opció közül kellett döntenük minden körben, a Khunen és Knutson (2005) tanulmányában ismertetett feladathoz hasonló keretek között. Az egyik döntés volt a jó, vagyis várható nyereséget jelentett, míg a másik döntés a rossz, ez várható veszteséget rejtett. Egy ideig minden körben ugyanaz volt a helyes döntés (azonban a képernyőn véletlenszerűen váltakozott a választások jelölésének helye), majd egy véletlen időpontban a döntések eredménye megfordult. A résztvevők minden

döntésük után láthatták, hogy mennyi pénzt nyertek (vagy vesztek) az aktuális körben és mennyit nyertek (vagy vesztek) addig a pontig összesen.

A kutatás eredménye azt mutatta, hogy amikor önállóan vizsgálták az agyi területek aktivitásának a magyarázóerejét, abban az esetben az anterior insula aktivitása volt az egyik leghatékonyabb előrejelző 62%-kal. Azonban a különböző agyi területek vizsgálatának kombinálásával 65 és 69 százalék közötti pontosságot tudtak elérni. Ebben az esetben három agyi terület aktivitásának együttesét vették, amelyek közül az egyik az MPFC volt. A tanulmány alátámasztotta, hogy a különböző agyi területekben megfigyelt aktivitás meghatározó eleme az emberek döntéseinek. Azt is bizonyította, hogy egyes agyi területek nagyobb szerepet játszanak a döntésekben, mint mások. Nem talált azonban kellő bizonyítékot arra, hogy az egyes agyi területek aktivitása, teljesen elkülönülve, más-más döntésekben járulnak hozzá a végső kimenetelhez (Hampton és O'Doherty, 2007).

A kutatásomhoz leginkább kapcsolódó tanulmány, amelyben a várakozási hatást, az agyi területek aktivitásának és az egyének befektetési döntéseinek kapcsolatát vizsgálták, Knutson és szerzőtársai (2008b) tanulmánya. Azt vizsgálták fMRI segítségével, hogy az alanyok befektetési döntéseit hogyan befolyásolják az azoktól teljesen független ösztönzők.

Az alanyok (15 heteroszexuális férfi) a részvételért óránként 20 000 dollárt kaptak, valamint 10 000 dollárt, amelyet a játék során használhattak, ezen felül pedig a játékban elnyert összeget is megtarthatták (vagy a játékban elveszített összeggel kevesebbet tarthattak meg). Az egyes döntések várható értéke megegyezett (mivel zéróösszegű játékok voltak), csak a kimenetek valószínűsége változott. A feladat, amely során vizsgálták az agyi területekben az aktivitás szintjét, 54 körből állt (18 pozitív, neutrális és negatív). A körökben egy-egy képet láthattak az alanyok, amelyek a várakozási hatást fejtették ki az alanyokban. A pozitív ösztönzők erotikus képek voltak párokról, a negatívak kígyók vagy pókok, a neutrálisok pedig háztartási eszközök. A résztvevőket tájékoztatták róla, hogy a képek függetlenek a befektetési döntéseik kimenetelétől. Minden kör elején egy-egy szimbólumot láthattak, amely jelezte, hogy az adott kép, pozitív, negatív vagy neutrális lesz (próbakör segítségével ezt tudatosították az alanyokban). A várakozási hatás eléréséhez volt erre szükség. Ezt követően jelentek meg a képek, majd később a két opció (a kockázatosabb és a kevésbé kockázatos), amelyek közül választhattak az alanyok. A végén láthatták az aktuális kör eredményét, illetve azt is, hogy addig összesen mennyi pénzt kerestek (vagy vesztek) a játékkal. A résztvevők a feladat után értékelték a reakciójukat mindegyik képre, a valence és arousal dimenziókban (lásd. 1.ábra) (Knutson és szerzőtársai, 2008b).

Az egyének önbevallásai alapján elmondható, hogy a pozitív ösztönzők növelték a pozitív arousal dimenzió értékét, míg a negatív ösztönzők a negatív arousal értékét, a neutrális ösztönzőhöz képest. Ezen felül a pozitív ösztönző növelte a kockázatos befektetési döntés esélyét, valamint a kockázatos befektetési döntésre váltás esélyét is, a neutrálishoz képest. A negatív ösztönző esetében nem növekedtek az esélyeik. A kockázatos döntésre váltás a kevésbé kockázatos döntésre váláshoz képest, magasabb aktivitást eredményezett a bilaterális NAcc-ben és csökkentette az aktivitást az anterior insula-ban. A kutatás eredményei azt mutatják, hogy a várakozási hatás befolyásolja az NAcc-ben az aktivitás mértékét, az érzelmi tapasztalatot és a befektetési döntést. Ez a hatás akkor is megfigyelhető, ha a várakozási hatást kifejtő ösztönző, teljes mértékben független a döntéstől és annak kimenetelétől (Knutson és szerzőtársai, 2008b). Ez az eredmény konzisztens a hipotézisemmel, mely szerint az NBA döntők hatással lehetnek a részvényt piacra. Az NBA döntők mérkőzései látszólag a részvényt piactól és a részvények hozamától független események, azonban várakozási hatást fejthetnek ki az emberekre, amely befolyásolhatja a befektetési döntéseiket is.

1.3. A sportesemények és az érzelmi állapot kapcsolata

A sporteseményeknek rendkívüli nézettsége van világszerte. A sportszurkolók érzelmileg kötődnek a kedvenc csapataikhoz és az általuk játszott mérkőzések kimeneteleihez. A sportesemények, így jelentősen tudják befolyásolni a nézők érzelmi állapotát. Block és Heyes (2022) tanulmányukban azt vizsgálták milyen hatással van az emberek napi hangulata a velük interakcióba lépők napi hangulatával. Egy erőteljes egyenes arányú hatást figyeltek meg a kettő között, főleg negatív hangulat esetében. Egy ember naponta sok emberrel léphet interakcióba. Az interakció során két ember hatással van egymás hangulatára, majd ezek az emberek másokkal is interakcióba kerülnek a nap folyamán és részben továbbadják ezt a hatást. Ez azt jelenti, hogy az emberek napi hangulatát a számukra idegenek aznapi hangulata is jelentősen befolyásolhatja. Knoll és szerzőtársai (2014) tanulmányukban azt figyelték meg, hogy hogyan hat német szurkolók hangulatára a német válogatott egy győztes és egy vesztes mérkőzése. A kutatás alátámasztotta, hogy a győztes mérkőzések megtekintése jelentősen javította a nézők hangulatát. A vesztes mérkőzések ugyan csökkentették a nézők hangulatát, de a kapcsolat kevésbé bizonyult erőteljesnek.

1.4. A sportesemények és a részvényhozamok kapcsolata

A sportesemények és a részvényhozamok kapcsolatának vizsgálata is széles irodalomhoz vezethető vissza. Az irodalmi áttekintésem korábbi alfejezeteiben fejtettem ki, hogy milyen tényezőkön keresztül lehet közvetett befolyása a sporteseményeknek az a részvényhozamokra.

Payne és szerzőtársai (2018) tanulmányukban az NFL döntők részvénytőzsiára mért hatásait vizsgálták. Területi alapon határozták meg a részvények kiválasztását. A döntőben szereplő csapatok államaiban bejegyzett székhellyel rendelkező vállalatokat választották ki. Azt vizsgálták meg, hogy milyen hatással vannak a részvényhozamokra az NFL döntők. Ezt többféle bontásban tették meg. Külön vizsgálták a nyertes, vesztes, esélyesebb és esélytelenebb csapatok államaiban a hatásokat. A vállalatok részvényeit pedig vállalati méret szerinti bontásban is megfigyelték. Pozitív szignifikáns hatást mutattak ki mind a teljes vizsgált időszakban (két hét a mérkőzés előtt, illetve két hét utána), valamint a mérkőzést megelőzően is. Ez utóbbi a várakozási hatást támasztotta alá, amelyet a kutatásom cáfolt az NBA döntők esetében.

Galoppo és Boido (2020) tanulmányukban 11 977 futballmérkőzés segítségével vizsgálták a meccsek részvények áraira mért hatásait. Többféle nemzeti és kontinentális bajnokságot is megfigyeltek az elemzésük során. Kutatásuk eredménye azt mutatja, hogy a mérkőzések a kimenetelüktől függetlenül befolyásolják a részvények árait, amely konzisztens Payne és szerzőtársai (2018) tanulmányának eredményével.

Fan és Wang (2018) tanulmányukban a négy nagy amerikai sportbajnokságnak (NFL, NBA, NHL, MLB) a részvénytőzsiára mért hatásait vizsgálta. Az eredményeik azt mutatták, hogy a vesztes mérkőzések alacsonyabb részvényhozamokkal jártak együtt a helyi vállalatoknál, míg a győztesek magasabbakkal. Ez az eredmény inkonzisztens a kutatásom eredményével. Továbbá azt is megfigyelték, hogy a magasabb média figyelem csökkenti a győztes meccsek pozitív hatását a részvények hozamaira.

2. ADATOK ÉS MÓDSZERTAN

Előzetes hipotézisem szerint az NBA döntő mérkőzései hatással vannak a részvények hozamaira. Elemzésemben azt vizsgálom, hogy a 2011 és 2023 között játszott döntőkben szereplő csapatok államaiban bejegyzett székhellyel rendelkező vállalatok részvényeinek hozamaira milyen hatással vannak a döntő mérkőzései.

2.1. Adatok

Az kutatáshoz használt részvény és vállalati adatokat a Refinitiv Eikon Datastream segítségével töltöttem le. Az NBA döntők mérkőzéseinek adatait online forrásból szereztem (basketball-reference.com). Az eseményelemzés során Fama és French három faktoros modelljét alkalmaztam. A Fama és French faktorokat és a kockázatmentes hozamokat (risk-free return), Kenneth R. French online könyvtárából töltöttem le (www.tuck.dartmouth.edu). French rendszeres számításokat végez a faktorok meghatározására az Amerikai Egyesült Államok piacán. A faktorok visszamenőleg is korrigálva vannak. Az amerikai részvénytőkepiacok jelentős részét akartam lefedni, hogy valóban reprezentatív mintával dolgozhassak. A Nasdaq, az NYSE, az NYSE Mkt és az NYSE Arca minden részvényének teljes hozamát használtam 2011.03.01. és 2023.06.30. között. Ezen felül a részvénytőkepiacokon jelenlévő vállalatok nevét, székhelyét (állam szerint) és azonosítóját töltöttem le. Az adatokat összefűztem, hogy egy teljes adattáblával dolgozhassak, amely az említett adatokat tartalmazza. Ezt követően bontásokat végeztem, minden eseményhez külön adattáblát állítottam elő, amely az államok és megfigyelések száma alapján a megfelelő vállalatokat tartalmazta. Az események dátumait, a hozzájuk tartozó államokat és a megfigyelt vállalatok számát az 1. táblázat tartalmazza. Az események az NBA döntő mérkőzéseinek napjai voltak.

Évek	Mecsek időpontja	Az adott évi államok		Az eseményekhez tartozó vállalatok száma
2023	jun1, jun4, jun7, jun9, jun12	Colorado	Florida	183, 184, 184, 183, 182
2022	jun2, jun5, jun8, jun10, jun13, jun16	Kalifornia	Massachusetts	526, 529, 530, 531, 532, 526
2021	jul6, jul8, jul11, jul14, jul17, jul20	Arizona	Wisconsin	89, 89, 89, 89, 89, 89
2020	sep30, oct2, oct4, oct6, oct9, oct11	Kalifornia	Florida	515, 516, 518, 519, 513, 513
2019	may30, jun2, jun5, jun7, jun10, jun13	Kalifornia	Ontario	426, 428, 427, 427, 428, 430
2018	may31, jun3, jun6, jun8,	Kalifornia	Ohio	525, 528, 527, 526
2017	jun1, jun4, jun7, jun9, jun12	Kalifornia	Ohio	548, 549, 548, 549, 549
2016	jun2, jun5, jun8, jun10, jun13, jun16, jun19	Kalifornia	Ohio	590, 590, 593, 594, 595, 592, 591
2015	jun4, jun7, jun9, jun11, jun14, jun16	Kalifornia	Ohio	645, 642, 642, 641, 642, 641
2014	jun5, jun8, jun10, jun12, jun15	Texas	Florida	536, 538, 537, 536, 533
2013	jun6, jun9, jun11, jun13, jun16, jun18, jun20	Florida	Texas	515, 515, 515, 518, 520, 515
2012	jun12, jun14, jun17, jun19, jun21	Florida	Oklahoma	177, 178, 179, 179, 179

1. táblázat Az NBA döntők időpontjai, döntőben szereplő államok és az adott eseményhez felhasznált vállalatok száma


Az 1. táblázatban látható az év, amelyben az adott döntőt játszották, a döntők mérkőzéseinek időpontjai, a döntőkben szereplő csapatok államai és az egyes mérkőzésekhez tartozó mintákban szereplő részvények (amely megegyezik a vállalatokkal) száma.

Látható, hogy az Amerikai Egyesült Államokban az államok szerint nagyon eltérnek a vállalatok számai, így az egyes eseményekhez tartozó mintáim vállalatszám is nagy eltéréseket mutat. A legkisebb mintám 89 vállalat adatait tartalmazza, míg a legnagyobb 645 vállalatét. Az elemzésemet *R* program segítségével készítettem el.

2.2. Módszertan

Az eseményelemzéshez meg kellett határoznom meg kellett határoznom a becslési ablakot és az eseményablakot is, a 3. ábrán látható módon.

3. ábra Az eseményelemzés elemei



A 3. ábrán látható a becslési ablak, amely hosszát a becslési ablak kezdő időpontja T_0 és végső időpontja T_1 határoznak meg. Az eseményablak hosszát pedig az határozza meg, hogy az esemény t_1 körüli hány napos intervallumot figyelik meg (t_1-d : t_1+d). Az becslési ablak végső időpontja és az eseményablak kezdeti időpontja között húzódik egy adott hosszúságú kihagyott időszak.

A becslési ablak hosszát 255 napban határoztam meg Payne és szerzőtársai (2018) tanulmányából kiindulva. A becslési ablak 46 nappal az esemény időpontja előtt ért véget. Az eseményablak mindössze három napból állt, az eseményt megelőző hétköznapból az eseményt követő hétköznapból és az esemény napjából. A rövid ablakokra azért volt szükség, mert az NBA döntő mérkőzései között csupán pár nap telik el. A rövid időablak a mérkőzések hatásainak elkülönítését szolgálták. Az események az NBA döntő mérkőzései voltak, azonban a számítások során az események napjait korrigáltam. A mérkőzések időnként szombatra vagy vasárnapra estek, amelyeken nincsenek tőzsdei tranzakciók, így ezek napjait hétfőre módosítottam. Az esemény előtti és az azt követő napok esetében is biztosra mentem, hogy hétköznapokat vizsgáljak, így ne legyenek hiányzó adataim. Ez azonban az eseményablakok összefolyását okozta egyes esetekben. A teljes hozamokból határoztam meg az egyes vállalatok napi hozamait az (1) egyenlet alapján.

$$Napi\ hozam = \left(\left(\frac{Teljes\ hozam_{i,t}}{Teljes\ hozam_{i,t-1}} \right) - 1 \right) * 100 \quad (1)$$

Ahol:

- A teljes hozam_{i,t} a teljes hozam t-beli értéke az i részvényre vonatkozóan,
- a teljes hozam_{i,t-1} pedig az i részvény teljes hozamának t-1-beli értéke.

Ezután létrehoztam minden eseményhez egy-egy becslési és esemény ablakot. A becslési ablakokhoz és az eseményablakokhoz is kiválasztottam azokban az államokban bejegyzett vállalatokat, amelyekre az adott évekhez szükségem volt. Ezután a vállalatok számát tovább szűkítettem. A napi hozamokban, a három egymást követő nulla értékeket hiányzókra (NA) cseréltem. Csak azokat a vállalatokat tartottam meg, amelyeknek egy adott eseményhez kapcsolódó becslési ablakban legalább a napok felében és az eseményablakban pedig minden nap voltak megfigyelései. A kiválasztási folyamat lényege a túlélési torzítás kiszűrése volt. Fontos az azóta már csődbe ment (vagy tőzsdéről kivont), de a vizsgálat ideje alatt megfelelő megfigyelési számmal rendelkező vállalatok részvényeinek vizsgálata. Csupán működő vállalatok vizsgálata nagyban torzíthatja az elemzés eredményét. A napi hozamokban megfigyelt kiugró (outlier) értékeket kiszűrtem. A kiugró értékeket a (2) egyenlet segítségével határoztam meg.

$$Outlier = (Q1 - 4 * IQR; Q3 + 4 * IQR) \quad (2)$$

Ahol:

- Q1 az első kvartilis,

- Q3 a harmadik kvartilis,
- IQR pedig az első és a harmadik kvartilisok közti különbség.

A szokásos másfél helyett tehát az interkvartilis négyszeresét hagytam meg az értékek mozgásterén, minimum és maximum érték esetében is. Ezt azért tettem, mert a kiugró adatok szűrése is értékes információk elvesztéséhez vezethet. A napi hozamok nagy mértékű volatilitása miatt, így nagyobb mozgásteret hagytam az értékeknek, hogy kevesebb fontos információt veszítsenek.

A napi hozamokból meghatároztam az többlet hozamokat (excess return) a (3) egyenlet alapján.

$$\text{Többlet hozam}_{i,t} = \text{napi hozam}_{i,t} - RF_t \quad (3)$$

Ahol:

- Az i,t az adott részvény jelzése az adott napon,
- RF_t (risk-free rate) pedig a kockázatmentes hozam az adott napon.

A többlet hozam és a Fama French faktorok segítségével határoztam meg az egyes vállalatspecifikus bétákat a (4) egyenlet alapján, a becslési ablakban.

$$\text{Többlet hozam}_{i,t} = \alpha_i + \beta_{i,Mkt-RF}(Mkt - RF)_t + \beta_{i,SMB}SMB_t + \beta_{i,HML}HML_t + \varepsilon_{i,t} \quad (4)$$

Ahol:

- Az i,t az adott részvény jelzése az adott napon,
- az $MKT - RF$ a piaci faktor a kockázatmentes hozammal korrigálva,
- az SMB a small minus big faktor a kis- és nagy kapitalizációjú vállalatok hozameltéréseit reprezentálja,
- az HML a high minus low faktor, amely a magas és alacsony könyv szerinti érték/piaci érték hányadossal rendelkező vállalatok hozameltéréseit reprezentálja,
- a β_i -k pedig a faktorokhoz tartozó vállalat specifikus béták.

A (4) egyenlet adott faktorokhoz tartozó bétéinak segítségével számoltam ki az eseményablakban a várható hozamokat az (5) egyenlet alapján.

$$\text{Várható hozam}_{i,t} = RF_t + \hat{\beta}_{i,Mkt-RF}(Mkt - RF)_t + \hat{\beta}_{i,SMB}SMB_t + \hat{\beta}_{i,HML}HML_t \quad (5)$$

Ahol:

- Az i,t az adott részvény jelzése az adott napon,
- RF_t (risk-free rate) a kockázatmentes hozam az adott napon,

- az MKT – RF a piaci faktor a kockázatmentes hozammal korrigálva,
- az SMB a small minus big faktor a kis- és nagy kapitalizációjú vállalatok hozameltéréseit reprezentálja,
- az HML a high minus low faktor, amely a magas és alacsony könyv szerinti érték/piaci érték hányadossal rendelkező vállalatok hozameltéréseit reprezentálja,
- a $\hat{\beta}_i$ -k pedig a faktorokhoz tartozó vállalat specifikus becsült (a becslési ablak segítségével) béták.

A várható hozamokból pedig az abnormális hozamokat számoltam a (6) egyenlet alapján.

$$\text{Abnormális hozam}_{i,t} = \text{Várható hozamok}_{i,t} - \text{napi hozamok}_{i,t} \quad (6)$$

Ahol:

- Az i,t az adott részvény jelzése az adott napon.

Ezt követően a különböző eseményeket összefűztem egy új változó bevonásával, amely az esemény előtti napot, az esemény napját és az eseményt követő napot jelezte. Az így kapott napokon a vállalatok abnormális hozamainak átlagolásával számoltam ki az átlagos abnormális hozamokat, ezt a (7) egyenlet mutatja.

$$\text{Átlagos abnormális hozam}_t = \frac{\sum_{i=1}^N \text{Abnormális hozam}_{i,t}}{N} \quad (7)$$

Ahol:

- Az i,t az adott részvény jelzése az adott napon,
- N pedig a részvények száma.

Az abnormális hozamok összeadásával határoztam meg az egyes napok kumulált abnormális hozamait a (8) egyenlet alapján minden egyes napra. Majd ezek segítségével az időszak kumulált átlagos abnormális hozamát a (9) egyenlet alapján.

$$\text{Kumulált abnormális hozam}_{T1,T2} = \sum_{T=T1}^{T2} \text{Abnormális hozam}_{i,t} \quad (8)$$

Ahol:

- Az i,t az adott részvény jelzése az adott napon,
- N a részvények száma,
- T1 a kezdő időpont,
- T2 pedig a végső időpont.

$$Kummulált\ átlagos\ abnormális\ hozam_{T1,T2} = \frac{1}{N} \sum_{i=1}^N Kummulált\ abnormális\ hozam_{i,t} \quad (9)$$

Ahol:

- Az i,t az adott részvény jelzése az adott napon,
- N a részvények száma,
- T1 a kezdő időpont,
- T2 pedig a végső időpont.

Végül a kiértékeléshez a kumulált átlagos abnormális hozamokhoz használt keresztmetszeti T-próbát alkalmaztam a (10) egyenlet alapján.

$$TKummulált\ átlagos\ abnormális\ hozam_t = \frac{Kummulált\ átlagos\ abnormális\ hozam_t}{\hat{S}(Kummulált\ átlagos\ abnormális\ hozam_t)} \quad (10)$$

Ahol:

$$\hat{S}^2(CAAR_t) = \frac{1}{N-1} \sum_{i=1}^N (CAR_{i,t} - CAAR_t)^2 \quad (11)$$

Ahol:


- $CAAR_t$ a kumulált átlagos abnormális hozam egy adott napon,
- $CAR_{i,t}$ a kumulált abnormális hozama egy adott részvénynek egy adott napon,
- N pedig a részvények száma.

3. EREDMÉNYEK

Az elemzés során azt vizsgáltam, hogy az NBA döntő mérkőzései jelentős befolyással vannak-e az részvénypiacra. Kutatásom azt mutatja, hogy nincsenek a mérkőzéseknek szignifikáns hatása a részvények alakulására. További elemzések szükségesek azonban a hatás teljes kizárásához. A következő fejezetben részletesen kifejtem, hogy melyek voltak azok a tényezők, amelyek nehezítették az egyes mérkőzések önálló hatásainak megfigyelését.

Az elemzéshez 68 eseményt vettem alapul, amelyek a 2012 és 2023 közötti NBA döntők mérkőzései voltak. Először minden egyes eseményhez külön eseményablakot és becslési ablakot határoztam meg, ezek segítségével kiszámoltam az egyes vállalatok abnormalis hozamait az eseményablakokban. Majd a kumulált abnormalis hozamait is meghatároztam az egyes vállalatoknak. A különböző években létrehozott eseményablakokat összefűztem. Három sort hoztam létre, amelyek az esemény előtti napot, az esemény napját és az eseményt követő napot jelölték. Ez alapján számoltam ki az egyes napokon a kumulált átlagos abnormalis hozamokat. Ezeket kumulált átlagos abnormalis hozamokhoz használt keresztmetszeti t-próbával teszteltem. A kumulált átlagos abnormalis hozamok alakulását az 4. ábra mutatja.

4. ábra A Kumulált átlagos abnormalis hozamok alakulása



Az eredmények a 2. táblázatban láthatóak.

2. Táblázat A kumulált átlagos abnormális hozamok és a hozzájuk tartozó T-próbák

NAP	CAAR	Tpróba
-1	0.0628	0.0253
0	0.0285	0.0084
1	0.0868	0.0215

A táblázat első oszlopában szerepelnek az eseményablak napjai, a másodikban a kumulált átlagos abnormális hozamok (százalékos formában megjelölve), a harmadikban pedig a t-próbák értékei. Mivel a t-próbák értékeinek abszolút értékei jóval kisebbek 1,96-nál így a kumulált átlagos abnormális hozamok bár enyhén pozitívak, de nem szignifikánsak. Ez alapján az NBA döntők mérkőzései 2011 és 2023 között jellemzően nem befolyásolták a részvények hozamait. Azonban további kutatások szükségesek a hatások teljes kizárásához.

3.1. Eredmények limitációi és további vizsgálatok lehetőségei

Számos tényező hátráltatta az elemzést, amelyek hozzájárulhattak az eredmények inszignifikanciájához. Az NFL döntőkhöz képest (amelyeket Payne és szerzőtársai (2018) tanulmányukban megvizsgáltak) az NBA döntők hatásait felmérni nehezebb, mivel nem teljesül több, az események hatásainak elkülönülő megfigyeléséhez szükséges kritérium.

Az NBA döntők nézettsége bár számottevő, de jóval kisebb, mint az NFL döntőké. Emellett míg az NFL döntő csupán egy mérkőzésből áll, addig az NBA döntők legalább négy, legfeljebb hét meccsből állnak, ami tovább csökkentheti egyetlen mérkőzésnek a hatását. Ezek között a meccsek között csupán pár nap telik el, valamint a hétvégi meccsek miatt a vizsgálat szükségessé teszi az eseményablakok egybefonódását. Hétvége helyett ugyanis, amikor nincsenek tőzsdei tranzakciók, hétköznapiakat kell venni a hiányzó megfigyelések elkerüléséhez. Az egyes események önálló hatásainak megfigyelését ez nehézkessé teszi. Az is nehezíti a hatások megfigyelését, hogy míg az NFL döntőknél a rájátszás utolsó mérkőzése után két hét szünet előzi meg az NFL döntő mérkőzését, addig az NBA döntők pár nappal a rájátszás utolsó mérkőzése után kezdődnek. Az NBA döntő előtt tehát sokkal kisebb eséllyel alakul ki várakozási hatás az emberekben.

Az NBA döntők hatásait a részvénytőzsiacra nem lehet teljesen kizárni az elemzés alapján. További lehetőségeket érdemes megvizsgálni a jövőben a hatás kizárása vagy alátámasztása érdekében. Érdemes külön megfigyelni a nyertes, a vesztes, az esélytelen és az esélyesebb

csapatok bontása alapján, hogy milyen hatásai vannak a döntőknek. Továbbá a vállalatok méretei szerinti felosztásban is megvizsgálni a részvényekre mért hatásokat. Payne és szerzőtársai (2018) tanulmányában a kisebb méretű vállalatok esetében volt megfigyelhető jellemzően szignifikáns hatás, míg a nagyobb piaci kapitalizációjú vállalatok esetében nem.

4. ÖSSZEFOGLALÁS

Tanulmányomban megvizsgáltam, hogy van-e hatása az NBA döntők mérkőzéseinek a részvények hozamaira. A mérkőzéseknek, a döntőben szereplő csapatok államaiban bejegyzett székhellyel rendelkező vállalatok részvényeinek hozamaira mért hatását vizsgáltam. Előzetes hipotézisemet, mely szerint a hatás megfigyelhető ráadásul nem csak a mérkőzést követően, de azt megelőzően is, cáfolta a kutatásom. A kutatás során reprezentatív mintával dolgoztam, minden Nasdaq, NYSE, NYSE Mkt és NYSE Arca részvénytőzsdéken 2011 és 2023 között kereskedett részvény volt a mintám, amelyeket tovább szűrtem az elemzésemhez. A szignifikáns eredmény kimutatását számos tényező hátráltatta, az NFL döntőhöz képest, ahol Payne és szerzőtársai (2018) szignifikáns hatást mutattak ki. Az NBA-nek kisebb a nézettsége és a döntők több meccsből állnak, amely elaprózza a hatást. A mérkőzések között kevés idő telik el, ez az eseményablakok egybefonódását is okozza. A rájátszás után pedig csak pár nap szünet van az döntőig, amely nem hagyja kibontakozni a várakozási hatást. A továbbiakban érdemes lehet bontásokat elvégezni, vesztes, nyertes, esélyes és esélytelenebb csapatok szerint, valamint vállalati méret alapján is.

IRODALOMJEGYZÉK

Block, P., & Burnett Heyes, S. (2022). Sharing the load: Contagion and tolerance of mood in social networks. *Emotion*, 22(6), 1193.

Fan, Q., & Wang, T. (2018). Game day effect on stock market: Evidence from four major sports leagues in US. *Journal of Behavioral and Experimental Finance*, 20, 9-18.

Galloppo, G., & Boido, C. (2020). How much is a goal in the football championship worth? Match results and stock price reaction. *International Journal of Sport Finance*, 15(2), 83-92.

Grosenick, L., Greer, S., & Knutson, B. (2008). Interpretable classifiers for fMRI improve prediction of purchases. *IEEE transactions on neural systems and rehabilitation engineering*, 16(6), 539-548.

Hampton, A. N., & O'doherty, J. P. (2007). Decoding the neural substrates of reward-related decision making with functional MRI. *Proceedings of the national Academy of sciences*, 104(4), 1377-1382.

http://mba.tuck.dartmouth.edu/pages/faculty/ken.french/data_library.html

<https://www.basketball-reference.com/>

<https://www.statista.com/chart/28107/sports-followed-by-americans/>

Knoll, J., Schramm, H., & Schallhorn, C. (2014). Mood effects of televised sports events: The impact of FIFA World Cups on viewers' mood and judgments. *Communication & Sport*, 2(3), 242-260.

Knutson, B., & Greer, S. M. (2008). Anticipatory affect: neural correlates and consequences for choice. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 363(1511), 3771-3786.

Knutson, B., Rick, S., Wimmer, G. E., Prelec, D., & Loewenstein, G. (2007). Neural predictors of purchases. *Neuron*, 53(1), 147-156.

Knutson, B., Wimmer, G. E., Kuhnen, C. M., & Winkielman, P. (2008b). Nucleus accumbens activation mediates the influence of reward cues on financial risk taking. *NeuroReport*, 19(5), 509-513.

- Knutson, B., Wimmer, G. E., Rick, S., Hollon, N. G., Prelec, D., & Loewenstein, G. (2008c). Neural antecedents of the endowment effect. *Neuron*, 58(5), 814-822.
- Kuhnen, C. M., & Knutson, B. (2005). The neural basis of financial risk taking. *Neuron*, 47(5), 763-770.
- Osgood, C. E., Suci, G. J. & Tannenbaum, P. H. 1957 The measurement of meaning. Urbana, IL: University of Illinois Press.
- Payne, B. C., Tressl, J., & Friesen, G. C. (2018). Sentiment and stock returns: Anticipating a major sporting event. *Journal of Sports Economics*, 19(6), 843-872.
- Russell, J. A. (1980). A circumplex model of affect. *Journal of personality and social psychology*, 39(6), 1161.
- Watson, D. & Tellegen, A. 1985 Toward a consensual structure of mood. *Psychol. Bull.* 98, 219–235.

MELLÉKLET

```
1 library(tidyverse)
2 library(readxl)
3 #Adatok beolvasása
4
5
6
7 ##Tickerek és székhelyek beolvasása
8
9 #Nasdaq_teljes
10 Nasdaq_teljes_address <- read_excel("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/Nasdaq_teljes.xlsx",
11                                     sheet = "Munka5") %>% select(1:3)
12
13 colnames(Nasdaq_teljes_address) <- c('ticker','hq','name')
14
15 #NYSE halott
16 NYSE_halott_address <- read_excel("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/NYSE_halott.xlsx",
17                                   sheet = "Munka4") %>% select(1:3)
18
19 colnames(NYSE_halott_address) <- c('ticker','name','hq')
20
21
22 #NYSE élő
23 NYSE_elő_address <- read_excel("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/NYSE_elő.xlsx",
24                                 sheet = "Munka4") %>% select(1:3)
25
26 colnames(NYSE_elő_address) <- c('ticker','name','hq')
27
28 #NYSE Mkt és NYSE Arca teljes
29 NYSEMkt_NYSEArca_teljes_address <- read_excel("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/NYSEMKT_NYSEARCA_teljes.xlsx",
30                                                sheet = "Munka4") %>% select(1:3)
31
32 colnames(NYSEMkt_NYSEArca_teljes_address) <- c('ticker','name','hq')
33
34 ##A székhelyadatok összefűzése
35 szekhely <- rbind(Nasdaq_teljes_address, NYSE_halott_address, NYSE_elő_address, NYSEMkt_NYSEArca_teljes_address)
36
37 View(szekhely)
38
39
40
41
42
43 #Fama french faktorok beolvasása
44 famafrrench <- read_csv("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/F-F_Research_Data_Factors_daily.CSV", skip = 4)
45
46 names(famafrrench)[1] <- "date"
47
48 famafrrench <- famafrrench %>%
49   mutate(date = lubridate::ymd(date)) %>%
50   filter(date >= as.Date('2011-03-01') & date <= as.Date('2023-06-30'))
```

```
52
53 ##A részvények beolvasása
54
55 #Nasdaq részvények beolvasása
56 Nasdaq_teljes_tri <- read_excel("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/Nasdaq_teljes.xlsx",
57                                 sheet = "Munka2", skip = 1)
58
59
60 Nasdaq_teljes_tri <- Nasdaq_teljes_tri %>%
61   filter(code >= '2011-03-01' & code <= '2023-06-30')
62
63 Nasdaq_teljes_tri <- Nasdaq_teljes_tri %>% mutate_at(-1, as.numeric)
64
65 names(Nasdaq_teljes_tri)[1] <- "date"
66
67 #Halott nyse részvények beolvasása
68 NYSE_halott_tri <- read_excel("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/NYSE_halott.xlsx",
69                               sheet = "Munka2")
70
71 names(NYSE_halott_tri)[1] <- "date"
72
73 NYSE_halott_tri <- NYSE_halott_tri %>%
74   filter(date >= '2011-03-01' & date <= '2023-06-30')
75
76 NYSE_halott_tri <- NYSE_halott_tri %>% mutate_at(-1, as.numeric)
77
78 #Elő NYSE részvények beolvasása
79 NYSE_elő_tri <- read_excel("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/NYSE_elő.xlsx",
80                             sheet = "Munka2")
81
82 names(NYSE_elő_tri)[1] <- "date"
83
84 NYSE_elő_tri <- NYSE_elő_tri %>%
85   filter(date >= '2011-03-01' & date <= '2023-06-30')
86
87 NYSE_elő_tri <- NYSE_elő_tri %>% mutate_at(-1, as.numeric)
88
89 View(NYSE_elő_tri)
90
91 #NYSE Mkt és NYSE Arca teljes részvények beolvasása
92 NYSEMkt_NYSEArca_teljes_tri <- read_excel("~/Egyetemek/NGG/III.félév/TDK/Készítés/Adatok/NYSEMKT_NYSEARCA_teljes.xlsx",
93                                           sheet = "Munka2")
94
95 names(NYSEMkt_NYSEArca_teljes_tri)[1] <- "date"
96
97 NYSEMkt_NYSEArca_teljes_tri <- NYSEMkt_NYSEArca_teljes_tri %>%
98   filter(date >= '2011-03-01' & date <= '2023-06-30')
99
100 NYSEMkt_NYSEArca_teljes_tri <- NYSEMkt_NYSEArca_teljes_tri %>%
101   mutate_at(-1, as.numeric)
```

```

103 |
104 | ##A részvényhozamok összefűzése
105 merged_table <- merge(Nasdaq_teljes_tri, NYSE_halott_tri, by = "date")
106 merged_table <- merge(merged_table, NYSE_elo_tri, by = "date")
107 merged_table <- merge(merged_table, NYSEMkt_NYSEArca_teljes_tri, by = "date")
108 |
109 | #A székhely és a részvényadatok összeeszkábálása
110 merged_table <- merged_table %>% pivot_longer(cols = -1, names_to = "ticker", values_to = "total_return")
111 |
112 | össze_nagy_elo <- merge(szekhely, merged_table, by = "ticker") %>% arrange(ticker, date)
113 |
114 | ##A függvények megadása
115 |
116 | #Outlierek kiszűrése
117 | cap_outliers <- function(column) {
118 |   Q1 <- quantile(column, 0.25, na.rm = TRUE)
119 |   Q3 <- quantile(column, 0.75, na.rm = TRUE)
120 |   IQR <- Q3 - Q1
121 |   lower.threshold <- Q1 - 4 * IQR
122 |   upper.threshold <- Q3 + 4 * IQR
123 |
124 |   # Replace values
125 |   column <- ifelse(column < lower.threshold, as.numeric(lower.threshold), column)
126 |   column <- ifelse(column > upper.threshold, as.numeric(upper.threshold), column)
127 |   return(column)
128 | }
129 |
130 | #Hiányos adatú vállalatok kiszűrése
131 | replace_consecutive_zeros <- function(x) {
132 |   consecutive_zeros <- rle(x == 0)
133 |   is_zero_run <- consecutive_zeros$values
134 |   run_lengths <- consecutive_zeros$lengths
135 |   for (i in seq_along(is_zero_run)) {
136 |     if (is_zero_run[i] && run_lengths[i] >= 3) {
137 |       x[seq(sum(run_lengths[seq_len(i - 1)]), sum(run_lengths[seq_len(i)]))] <- NA
138 |     }
139 |   }
140 |   return(x)
141 | }
142 |
143 | #Hogy lássam hogyan halad a függvény
144 | print_progress <- function(iteration, total) {
145 |   percent <- round(iteration / total * 100, 1)
146 |   cat(sprintf("\rProgress: [%-50s] %5.1f%%",
147 |     paste(rep("=", floor(percent / 2)), collapse = ""),
148 |     percent))
149 | }
150 |
151 | #A fő függvény megadása
152 |

```

```

153 | odabe <- function(event_date, össze_nagy_elo, famafrench, states_per_year){
154 |
155 |   össze_nagy_elo <- össze_nagy_elo %>% filter(hq %in% unlist(states_per_year))
156 |
157 |
158 |   össze_nagy_elo <- össze_nagy_elo %>% group_by(ticker)%>%
159 |     mutate(daily = ((total_return/lag(total_return))-1)*100)
160 |
161 |
162 |   össze_nagy_elo <- össze_nagy_elo %>%
163 |     group_by(ticker) %>%
164 |     mutate(daily = replace_consecutive_zeros(daily))
165 |
166 |
167 |   össze_nagy_elo$daily <- cap_outliers(össze_nagy_elo$daily)
168 |
169 |
170 |   # Define event window dates
171 |   if (weekdays(event_date) == "szombat") {
172 |     # Adjust event date to Monday
173 |     event_date <- event_date + 2
174 |     # Adjust event window accordingly
175 |     event_start_date <- event_date - 3
176 |     event_end_date <- event_date + 1
177 |   } else if (weekdays(event_date) == "vasárnap") {
178 |     # Adjust event date to Tuesday
179 |     event_date <- event_date + 1
180 |     # Adjust event window accordingly
181 |     event_start_date <- event_date - 3
182 |     event_end_date <- event_date + 1
183 |   } else if (weekdays(event_date) == "péntek") {
184 |     # Adjust event date to Monday
185 |     event_date <- event_date
186 |     # Adjust event window accordingly
187 |     event_start_date <- event_date - 1
188 |     event_end_date <- event_date + 3
189 |   } else if (weekdays(event_date) == "hétfő") {
190 |     # Adjust event date to Friday
191 |     event_date <- event_date
192 |     # Adjust event window accordingly
193 |     event_start_date <- event_date - 3
194 |     event_end_date <- event_date + 1
195 |   } else {
196 |     # Define event window normally
197 |     event_start_date <- event_date - 1
198 |     event_end_date <- event_date + 1
199 |   }
200 |

```

```

201
202
203 # Define the length of the estimation window (in days) and event window
204 estimation_window_length <- 255
205
206 # Calculate the end date of the estimation window (1 day before the event)
207 estimation_end_date <- event_date - 46
208
209 # Calculate the start date of the estimation window
210 estimation_start_date <- estimation_end_date - estimation_window_length
211
212
213 # Create a data frame containing the dates within the estimation window
214 estimation_window_dates <- seq(estimation_start_date, estimation_end_date, by = "day")
215
216 # Calculate the dates within the event window
217 event_window_dates <- seq(event_start_date, event_end_date, by = "day")
218
219 # Subset data for estimation and event windows
220 estimation_window_df <- subset(ossze_nagy_elso, date >= estimation_start_date & date <= estimation_end_date)
221 event_window_df <- subset(ossze_nagy_elso, date >= event_start_date & date <= event_end_date)
222
223
224
225 # Calculate the number of non-NA values for each company in the estimation window
226
227
228 estimation_counts <- estimation_window_df %>% group_by(ticker) %>% summarise(NA_sum = sum(!is.na(daily))) %>%
229   filter(NA_sum >= (184/2))
230
231
232
233 event_counts <- event_window_df %>% group_by(ticker) %>% summarise(NA_sume = sum(!is.na(daily))) %>%
234   filter(NA_sume == 3)
235
236 companies <- inner_join(estimation_counts, event_counts, by = 'ticker')
237
238
239 selected_companies <- pull(companies, 1)
240
241
242 filtered_df <- subset(ossze_nagy_elso, ticker %in% selected_companies)
243
244 filtered_elso_estimation <- subset(filtered_df, date >= estimation_start_date & date <= estimation_end_date)
245
246 filtered_elso_event <- subset(filtered_df, date >= event_start_date & date <= event_end_date)
247
248
249 filtered_elso_estimation_fama <- left_join(filtered_elso_estimation, famafrench, by = 'date')
250

```

```

251
252 filtered_elso_event_fama <- left_join(filtered_elso_event, famafrench, by = 'date')
253
254 filtered_elso_estimation_fama$excess <- filtered_elso_estimation_fama$daily - filtered_elso_estimation_fama$RF
255
256 company_list <- unique(filtered_elso_estimation_fama$ticker)
257 company_data <- split(filtered_elso_estimation_fama, filtered_elso_estimation_fama$ticker)
258
259 # Step 2: Apply regression for each company
260 regression_results <- lapply(company_data, function(company_df) {
261   lm_model <- lm(excess ~ Mkt_RF + SMB + HML, data = company_df)
262   summary(lm_model) # Get summary of regression model
263 })
264
265 coefficients_list <- list()
266
267 # Iterate through each regression result
268 for (company_name in names(regression_results)) {
269   # Extract the coefficients from the summary
270   coefficients <- coef(regression_results[[company_name]])
271
272   # Store the coefficients in the list
273   coefficients_list[[company_name]] <- coefficients
274 }
275
276 # View the coefficients for each company
277 coefficients_list
278
279 coefficients_table <- data.frame(
280   Company = names(coefficients_list),
281   b1 = sapply(coefficients_list, "[", 1),
282   b2 = sapply(coefficients_list, "[", 2),
283   b3 = sapply(coefficients_list, "[", 3),
284   b4 = sapply(coefficients_list, "[", 4)
285 )
286
287
288
289 names(filtered_elso_event_fama)[names(filtered_elso_event_fama) == "ticker"] <- "Company"
290
291 # Step 2: Merge the coefficients_table with other_data_table based on the 'Company' column
292 merged_data_elso <- merge(filtered_elso_event_fama, coefficients_table, by = "Company")
293
294 # Step 3: Calculate expected returns for each company
295 merged_data_elso$expected <- with(merged_data_elso, {
296   RF + Mkt_RF * b2 + SMB * b3 + HML * b4
297 })
298
299 merged_data_elso$abnormal <- merged_data_elso$daily - merged_data_elso$expected
300

```

```

300 merged_data_elso_wide <- merged_data_elso %>% group_by(date) %>%
301   select(Company, date, hq, abnormal) %>%
302   pivot_wider(names_from = c(Company, hq), values_from = abnormal)
303
304
305
306 #ID-k hozzáadása
307 merged_data_elso_wide$day <- c(-1,0,1)
308
309 merged_data_elso_wide <- merged_data_elso_wide[, -1]
310
311 df_name <- paste0("caar_", format(event_date, "%Y%m%d"))
312
313 # Assign the data frame to the global environment with the generated name
314 assign(df_name, merged_data_elso_wide, envir = .GlobalEnv)
315
316 # Return a list containing the data frame and its name
317 return(list(df = merged_data_elso_wide, name = df_name))
318 }
319
320
321 #A dátumok megadása
322 event_dates <- as.Date(c("2012-06-12", "2012-06-14", "2012-06-17", "2012-06-19", "2012-06-21", "2013-06-16", "2013-06-18", "2013-06-20",
323   "2013-06-06", "2013-06-09", "2013-06-11", "2013-06-13", "2014-06-05", "2014-06-08", "2014-06-10", "2014-06-12", "2014-06-15",
324   "2015-06-04", "2015-06-07", "2015-06-09", "2015-06-11", "2015-06-14", "2015-06-16", "2016-06-02", "2016-06-05", "2016-06-08", "2016-06-10",
325   "2016-06-13", "2016-06-16", "2016-06-19", "2017-06-01", "2017-06-04", "2017-06-07", "2017-06-09", "2017-06-12",
326   "2018-05-31", "2018-06-03", "2018-06-06", "2018-06-08", "2019-05-30", "2019-06-02", "2019-06-05", "2019-06-07", "2019-06-10", "2019-06-13",
327   "2020-09-30", "2020-10-02", "2020-10-04", "2020-10-06", "2020-10-09", "2020-10-11", "2021-07-06", "2021-07-08", "2021-07-11", "2021-07-14",
328   "2021-07-17", "2021-07-20", "2022-06-02", "2022-06-05", "2022-06-08", "2022-06-10", "2022-06-13", "2022-06-16", "2023-06-01", "2023-06-04",
329   "2023-06-07", "2023-06-09", "2023-06-12"))
330
331
332
333
334
335
336 #A dátumokhoz tartozó államok megadása
337 states_per_year <- list(
338   c("FLORIDA", "FL", "Fla.", "OKLAHOMA", "OK", "Okla."),
339   c("FLORIDA", "FL", "Fla.", "OKLAHOMA", "OK", "Okla."),
340   c("FLORIDA", "FL", "Fla.", "OKLAHOMA", "OK", "Okla."),
341   c("FLORIDA", "FL", "Fla.", "OKLAHOMA", "OK", "Okla."),
342   c("FLORIDA", "FL", "Fla.", "OKLAHOMA", "OK", "Okla."),
343   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
344   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
345   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
346   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
347   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
348   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
349   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
350   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
351   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
352   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
353   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
354   c("FLORIDA", "FL", "Fla.", "TEXAS", "TX", "Tex."),
355   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
356   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
357   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
358   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
359   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
360   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
361   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
362   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
363   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
364   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
365   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
366   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
367   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
368   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
369   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
370   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
371   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
372   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
373   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
374   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
375   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
376   c("CALIFORNIA", "CA", "Cali.", "OHIO", "OH", "Ohio"),
377   c("CALIFORNIA", "CA", "Cali.", "ONTARIO", "ON", "Ont."),
378   c("CALIFORNIA", "CA", "Cali.", "ONTARIO", "ON", "Ont."),
379   c("CALIFORNIA", "CA", "Cali.", "ONTARIO", "ON", "Ont."),
380   c("CALIFORNIA", "CA", "Cali.", "ONTARIO", "ON", "Ont."),
381   c("CALIFORNIA", "CA", "Cali.", "ONTARIO", "ON", "Ont."),
382   c("CALIFORNIA", "CA", "Cali.", "ONTARIO", "ON", "Ont."),
383   c("CALIFORNIA", "CA", "Cali.", "FLORIDA", "FL", "Fla."),
384   c("CALIFORNIA", "CA", "Cali.", "FLORIDA", "FL", "Fla."),
385   c("CALIFORNIA", "CA", "Cali.", "FLORIDA", "FL", "Fla."),
386   c("CALIFORNIA", "CA", "Cali.", "FLORIDA", "FL", "Fla."),
387   c("CALIFORNIA", "CA", "Cali.", "FLORIDA", "FL", "Fla."),
388   c("CALIFORNIA", "CA", "Cali.", "FLORIDA", "FL", "Fla."),
389   c("ARIZONA", "AZ", "Ariz.", "WISCONSIN", "WI", "Wis.", "Wisc."),
390   c("ARIZONA", "AZ", "Ariz.", "WISCONSIN", "WI", "Wis.", "Wisc."),
391   c("ARIZONA", "AZ", "Ariz.", "WISCONSIN", "WI", "Wis.", "Wisc."),
392   c("ARIZONA", "AZ", "Ariz.", "WISCONSIN", "WI", "Wis.", "Wisc."),
393   c("ARIZONA", "AZ", "Ariz.", "WISCONSIN", "WI", "Wis.", "Wisc."),
394   c("ARIZONA", "AZ", "Ariz.", "WISCONSIN", "WI", "Wis.", "Wisc."),
395   c("CALIFORNIA", "CA", "Cali.", "MASSACHUSETTS", "MA", "Mass."),
396   c("CALIFORNIA", "CA", "Cali.", "MASSACHUSETTS", "MA", "Mass."),
397   c("CALIFORNIA", "CA", "Cali.", "MASSACHUSETTS", "MA", "Mass."),
398   c("CALIFORNIA", "CA", "Cali.", "MASSACHUSETTS", "MA", "Mass."),
399   c("CALIFORNIA", "CA", "Cali.", "MASSACHUSETTS", "MA", "Mass."),

```

```

400 c("CALIFORNIA", "CA", "Cali.", "MASSACHUSETTS", "MA", "Mass."),
401 c("COLORADO", "CO", "Colo.", "FLORIDA", "FL", "Fla."),
402 c("COLORADO", "CO", "Colo.", "FLORIDA", "FL", "Fla."),
403 c("COLORADO", "CO", "Colo.", "FLORIDA", "FL", "Fla."),
404 c("COLORADO", "CO", "Colo.", "FLORIDA", "FL", "Fla."),
405 c("COLORADO", "CO", "Colo.", "FLORIDA", "FL", "Fla.")
406 )
407 }
408 #Egy lista készítése az eredményeknek
409 results_list <- list()
410
411 #A függvény futtatása!
412
413 for (i in 1:length(event_dates)) {
414   print_progress(i, length(event_dates))
415   # Get the event date and states for the current event
416   event_date <- (event_dates[i])
417   states <- states_per_year[[i]]
418
419   # Call the function for the current event
420   result <- odabe(event_date, össze_nagy_elso, famaafrench, states)
421
422   # Store the result in the list
423   results_list[[i]] <- result
424 }
425
426 #Egy adathalmaz készítése az adatok kinyeréséhez
427 merged_df <- data.frame(day = c(-1, 0, 1))
428
429 #Az adathalmaz feltöltése
430 for (i in 1:length(results_list)) {
431   print_progress(i, length(results_list))
432   # Get the name of the data frame containing the abnormal returns for the current event
433   df_name <- results_list[[i]]$name
434
435   # Retrieve the data frame from the global environment
436   event_df <- get(df_name, envir = .GlobalEnv)
437
438   # Merge the event's data frame with the merged data frame based on the 'day' variable
439   merged_df <- merge(merged_df, event_df, by = "day", all = TRUE)
440 }
441
442 #Átlagos abnormalis hozamok előállítása
443 merged_df$AAR <- rowMeans(merged_df[, -1], na.rm = TRUE)
444
445 View(merged_df)
446
447 #Kumulatív hozamok ábrázolása
448

```

```

450 new <- merged_df %>% select("day", "CAAR")
451
452 new$day <- as.Date(new$day)
453
454
455
456 wilcox_test_result <- wilcox.test(merged_df$CAR, mu = 0, alternative = "two.sided") # Test if CAARs are significantly different from zero
457 CAAR <- mean(merged_df$CAR)
458
459
460 #Kumulatív abnormalis hozamok kiszámolása
461 car_df <- data.frame(merged_df[, 1]) # Assuming the first column of merged_df is used as the index
462
463 # Get column names except the first and last
464 cols_to_process <- names(merged_df)[-c(1, length(merged_df))]
465
466 # Loop through each column
467 for (col in cols_to_process) {
468   # Calculate cumulative abnormal returns (CARs) for the current column
469   car_df[[paste0(col, "_CAR")]] <- cumsum(merged_df[[col]])
470 }
471
472 names(car_df)[1] <- "day"
473
474 View(car_df)
475
476 #CAAR tesztelése
477 car_test <- data.frame(day = c(-1, 0, 1))
478
479 car_test$scaar_sq <- apply(car_df, 1, function(row) var(row, na.rm = TRUE))
480
481 car_test$caar <- rowMeans(car_df[, -1], na.rm = TRUE)
482
483
484 View(car_test)
485
486 car_test$t_test <- car_test$caar/sqrt(car_test$scaar_sq)
487
488 car_test$day <- as.Date(car_test$day)
489
490 ggplot(car_test, aes(x = day, y = caar)) +
491   geom_line() + geom_point() + scale_x_date(name = "Eseményablak napjai", date_breaks = "1 day", date_labels = ("%d")) +
492   scale_y_continuous(name = "Kumulatív átlagos abnormalis hozamok") +
493   ggtitle("Kumulatív átlagos abnormalis hozamok az összesített eseményablakban") +
494   theme_replace() +
495   theme(axis.text.x = element_text(angle = 0, hjust = 1))
496

```

I.Melléklet

Az elemzéshez írt R kód