

Volatilitás-terjedés vizsgálata az Európai Unió biztosítási szektorában, VAR modellek segítségével

Szakdolgozat

Írta: Horváth Adél Roxána

Biztosítási és Pénzügyi Matematika Msc szak
Aktuárius specializáció

Témavezető: Kovács László



Budapesti Corvinus Egyetem
Eötvös Loránd Tudományegyetem

2025

Tartalomjegyzék

1. Bevezetés	1
2. A vektor-autoregresszív modell	2
2.1. A VAR modellek impulzusválasz-analízisének bevezetése	4
2.1.1. Előrejelzési hiba impulzusválasz	4
2.1.2. Az azonosítási probléma	5
2.1.3. Ortogonális impulzusválaszok	5
3. A Diebold-Yilmaz 2012-es keretrendszer	7
3.1. Az általánosított volatilitás-átterjedés és mérése	9
3.1.1. Varianciahányadok	10
3.1.2. Teljes volatilitás-átterjedés	11
3.1.3. Irányított-átterjedés	11
3.1.4. Nettó átterjedés	12
3.1.5. Nettó páronkénti átterjedés	12
4. A keretrendszer és más megközelítések korábbi alkalmazási területei a volatilitás-átterjedés vizsgálatában	13
4.1. Volatilitás-átterjedések mérése az amerikai eszközosztályok között	14
4.2. Volatilitás-átterjedések mérése az európai olaj- és gáziparban	16
4.3. Nyersanyagárak volatilitása a Covid alatt	17
4.4. Volatilitás-átterjedések mérése bankok és biztosítók között	18
5. Az Európai Unió biztosítók	20
6. A részvényárfolyamok volatilitás terjedése az Európai Unió biztosító-társaságok között	25
6.1. Az adatok bemutatása	25
6.2. Teljes mintaelemzés	29
6.2.1. Alapvető idősoros modellek: $\text{VAR}(p)$, $\text{MA}(q)$, impulzus-válaszfüggvény, előrejelzési hiba variancia	29

6.2.2.	Teljes mintás spillover tábla	29
6.3.	Teljes minta szerinti connectedness tábla	32
6.3.1.	Teljes mintás FEVD hálózatként való ábrázolása	33
6.4.	Mozgóablakos alkalmazás – Spillover vs. Connectedness	34
6.4.1.	Spillover és Connectedness Indexek	35
6.4.2.	Teljes irányított kapcsolódás és volatilitás-átterjedés	36
6.4.3.	Mozgóablakos Nettó Kétváltozós Spillover és Connectedness	40
6.5.	A tőke alapján rangsorolt EU-s biztosítótársaságok modellje	43
6.5.1.	Tőke alapú rangsorolás: Teljes mintás FEVD hálózatként való ábrázolás	47
6.5.2.	Tőke alapú rangsorolás: Spillover és Kapcsolódási indexek	48
6.5.3.	Tőke alapú rangsorolás: teljes irányított kapcsolódás és volatilitás-átterjedés	49
6.5.4.	Tőke alapú rangsorolás: Mozgóablakos Nettó Kétváltozós Spillover és Kapcsolódás	52
7.	Összefoglalás	54
	Irodalomjegyzék	56

Ábrák jegyzéke

6.1. A logaritmikus volatilitás	27
6.2. A vállalati kapcsolódás ábrája	34
6.3. Spillover (Ortogonalis) és Connectedness (Nem ortogonalis) indexek	35
6.4. Volatilitás átadás	37
6.5. Volatilitás fogadás	38
6.6. Nettó volatilitási összekapcsoltság	39
6.7. Kétváltozós kapcsolódás az SCOR SE (SCR.PA) és az ALLIANZ (ALV.DE) között	40
6.8. Kétváltozós kapcsolódás az a Generali(G.MI) és a Crédit Agricole S.A. (ACA.PA) között	41
6.9. Kétváltozós kapcsolódás az Allianz (ALV.DE) és a Generali(G.MI) között .	41
6.10. Tőke alapú rangsorolás: logaritmikus volatilitás	43
6.11. Tőke alapú rangsorolás: vállalati kapcsolódás ábrája	47
6.12. Tőke: Spillover (Ortogonalis) és Kapcsolódási (Nem ortogonalis) indexek .	48
6.13. Tőke: Volatilitás átadás	49
6.14. Tőke: Volatilitás fogadás	50
6.15. Tőke: Nettó volatilitási összekapcsoltság	51
6.16. Kétváltozós kapcsolódás az Allianz (ALV.DE) és az NN(NN.AS) között . .	52
6.17. Kétváltozós kapcsolódás az AXA (CS.PA) és az Allianz (ALV.DE) között .	53

Táblázatok jegyzéke

4.1. Volatilitás áttekintési táblázat, négy eszközosztály. Forrás: Diebold és Yilmaz (2012)	14
5.1. Az Európai Unió legnagyobb biztosítói bruttó díjbevétel alapján (2022). Forrás: Reinsurance News (2024)	20
5.2. Az Európai Unió legnagyobb biztosítói tőke alapján (2022). Forrás: Reinsurance News (2024)	21
6.1. Részvények évesített volatilitásának statisztikai jellemzői	28
6.2. Volatility Spillovers	31
6.3. Volatility Connectedness	32
6.4. Tőke alapú részvények évesített volatilitásának statisztikai jellemzői	44
6.5. Tőke: Volatility Spillovers	45
6.6. Tőke: Volatility Connectedness	46

Köszönetnyilvánítás

Ezúton szeretném megköszönni Kovács Lászlónak, konzulensemnek a dolgozatom elkészítése során nyújtott segítségét és támogatását. Mindvégig készségesen állt rendelkezésemre, kérdéseimre gyorsan és alapos válaszokat adott, valamint szakmai tanácsaival jelentősen hozzájárult a munkám színvonalának emeléséhez.

1. fejezet

Bevezetés

A dolgozatban az Európai Unió biztosítási szektorának szereplői között jelen lévő volatilitás-terjedést vizsgálom vektor autoregressziós modellek (VAR) segítségével, 2018 januárjától 2024 decemberéig terjedő időszakra vonatkozóan. A VAR-modell lehetőséget ad arra, hogy egyszerre elemezzük több biztosítótársaság részvényárfolyamának volatilitását és azok kölcsönhatásait, ezáltal pontosan feltérképezhetjük a piaci ingadozások és sokkok terjedését és az egyes sokkokat először érzékelő biztosítási társaságokat az európai biztosítási piacon. A módszertan használatához nagy segítséget nyújtanak azon korábbi tanulmányok, amelyek a volatilitás terjedését VAR modellekkel írják le. Diebold és Yilmaz (2012) a volatilitás-terjedés prediktív mérésére, Huszár et al. (2023) az olaj- és gázipari volatilitás-átadások dinamikájára, valamint Mroua és Lamine (2024) a COVID-19 pandémia alatt a nyersanyagok diverzifikációs előnyeire vonatkozó munkái alapvető betekintést nyújtanak a volatilitás terjedésének modellezésének kihívásaiba. Mindegyik munka a volatilitás terjedését a VAR modellezésre épülő Diebold-Yilmaz indexek keretrendszerében oldja meg.

A kutatás fő célja a volatilitás-terjedési minták azonosítása és a legfontosabb kockázati tényezők feltárása az Európai uniós biztosítási szektorban, elsőként a 2018-2020 közötti pénzügyi válsággal nem terhelt időszakban, majd 2020-2022 közötti COVID válság alatt, végül pedig a 2022-2024 közötti orosz-ukrán háború időszaka alatt. A kutatásom eredményei rávilágítanak arra, hogyan hatnak egymásra a biztosítók részvényárfolyamainak ingadozásai, és hogy ezek a volatilitás-terjedés mintázatok, hogyan befolyásolják a piaci stabilitást. Ezen információk segítséget nyújthatnak a biztosítótársaságok kockázatkezelési stratégiáinak finomításában és a piaci ingadozások hatékonyabb kezelésében, hozzájárulva ezzel az európai biztosítási szektor pénzügyi stabilitásának megőrzéséhez.

2. fejezet

A vektor-autoregresszív modell

Ezen alfejezet alapjául elsősorban Haslbeck et al. (2021) cikke szolgált.

A vektor-autoregresszív (VAR) modellek általános megközelítést kínálnak a többváltozós idősorok modellezésére. Az elsőrendű vektor-autoregresszív (VAR(1)) modellben minden változó értékét az összes többi változó – beleértve önmagát is – előző időpontbeli értékei alapján becsülik meg. A modell a konstans (intercept) paramétereken (azt jelzi, hogy mekkora lenne a változó alapértelmezett szintje, ha a többi tényező hatása nem érvényesülne) kívül két fő típusú hatást tartalmaz: az autoregresszív hatásokat, amelyek azt mutatják, hogy egy adott változó előző időpontbeli értéke mennyiben befolyásolja annak aktuális értékét, valamint a kereszt-késleltetett hatásokat, amelyek azt fejezik ki, hogy az összes többi változó előző időpontbeli értékei milyen mértékben hatnak az adott változó aktuális értékére.

Formálisan, a $\mathbf{X}_t \in \mathbb{R}^p$ változók az $t \in \mathbb{Z}$ időpontban a korábbi időpontban ($t - 1$) lévő ugyanazon változók lineáris kombinációjaként vannak modellezve:

$$\mathbf{X}_t = \beta_0 + \mathbf{B}\mathbf{X}_{t-1} + \boldsymbol{\varepsilon} = \begin{bmatrix} \beta_{0,1} \\ \vdots \\ \beta_{0,p} \end{bmatrix} + \begin{bmatrix} \beta_{1,1} & \cdots & \beta_{1,p} \\ \vdots & \ddots & \vdots \\ \beta_{p,1} & \cdots & \beta_{p,p} \end{bmatrix} \begin{bmatrix} X_{t-1,1} \\ \vdots \\ X_{t-1,p} \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_p \end{bmatrix}. \quad (2.1)$$

Ahol $\beta_{0,1}$ az első változó konstans tagja, $\beta_{1,1}$ az $X_{t-1,1}$ autoregresszív hatása az $X_{t,1}$ -re, és $\beta_{p,1}$ az $X_{t-1,p}$ kereszt-késleltetett hatása az $X_{t,1}$ -re. Fontos megjegyezni, hogy az X_{t-1} vektor minden változó $t - 1$ időpontbeli értékét tartalmazza, így a kereszt-késleltetett hatások több változóra is kiterjedhetnek. A $\beta_{p,1}$ index itt csak a legutolsó, p -edik változó hatását jelöli, de a modell figyelembe veszi az összes többi változó korábbi értékének hatását is az adott változóra. Feltételezzük, hogy $\boldsymbol{\varepsilon} = \{\varepsilon_1, \dots, \varepsilon_p\}$ független (az időpontok között) minták egy többváltozós normális eloszlásból, melynek variancia-kovariancia mátrixa Σ . A Σ -t kinyerhető a modell maradékaiból, és felhasználható az inverz kovariancia mátrix becslésére (lásd például Epskamp et al. (2018)).

Az elsőrendű VAR modellekben az időpontban (t) lévő összes változó az előző időpontban $(t - 1)$ lévő összes változó lineáris függvénye. További késleltetések is bevonhatók a modellbe az (2.1) egyenletben szereplő további paramétermátrixok és késleltetett változók $\mathbf{X}_{t-k}$ (egy k késleltetés esetén) hozzáadásával.

Az (2.1) egyenletben szereplő modellt úgy becsüljük meg, hogy az $\mathbf{X}_{t,i}$ változókat ($i \in \{1, \dots, p\}$) külön-külön prediktáljuk. Konkrétan, az alábbi módon modellezzük:

$$X_{t,i} = \beta_{0,i} + \mathbf{b}_i \mathbf{X}_{t-1} + \varepsilon_i = \beta_{0,i} + \begin{bmatrix} b_{i,1} & \dots & b_{i,p} \end{bmatrix} \begin{bmatrix} X_{t-1,1} \\ \vdots \\ X_{t-1,p} \end{bmatrix} + \varepsilon_i, \quad (2.2)$$

minden $i \in \{1, \dots, p\}$ esetén, ahol β_i egy $1 \times p$ vektor, amely az $\mathbf{X}_{t,i}$ késleltetett hatásait tartalmazza. Miután az egyes egyenletek paramétereit megbecsültük, az összes becslést kombináljuk az (2.1) egyenlet VAR modelljébe.

Az (2.1) állandó VAR modellt időben változó VAR modellé alakítjuk úgy, hogy a paramétermátrixokhoz időindexet vezetünk be:

$$\mathbf{X}_t = \boldsymbol{\beta}_{0,t} + \mathbf{B}_t \mathbf{X}_{t-1} + \boldsymbol{\varepsilon}_t, \quad (2.3)$$

Ez lehetővé teszi a VAR modell paraméterezésének változását minden időpontban, és ezzel az időbeli változékonyságot. A modellben szereplő hibatag, azaz a $\boldsymbol{\varepsilon}_t$ vektor nemcsak az egyes időpontokhoz tartozó előrejelzési hibákat tartalmazza, hanem azok statisztikai tulajdonságai is időben változhatnak. Ennek megfelelően a reziduum kovariancia-mátrixa, amelyet $\boldsymbol{\Sigma}_t = \text{Cov}(\boldsymbol{\varepsilon}_t)$ jelöl, szintén időfüggő.

A VAR modellt gyakran hálózati modellként tárgyalták és vizualizálták (Epskamp et al. (2018)), és jelen dolgozatban is mind statisztikai, mind hálózati/ gráfelméleti terminológiát fogunk használni. A két terminológia között a kifejezések a következőképpen felelnek meg egymásnak:

A statisztikai perspektívából két típusú késleltetett hatás létezik a változók párpai között:

- Autokorrelációk (például $\mathbf{X}_{t-1} \rightarrow \mathbf{X}_t$), és
- Kereszt-késleltetett hatások (például $\mathbf{X}_{t-1} \rightarrow \mathbf{Y}_t$).

A hálózati terminológiában a változók csomópontok, a késleltetett hatások pedig irányított élekkel vannak reprezentálva. Egy él, amely egy adott csomópontba mutat saját magáról, *önhurok*-nak (*self-loop*) is nevezhető, amely az autokorrelációs hatásokat képviseli. A késleltetett hatások értékét az irányított él súlyainak előjele és abszolút értéke fejezi ki. Ha az $\mathbf{X}_{t-1}$ és $\mathbf{X}_t$ közötti él-súly nem nulla, azt mondjuk, hogy az él jelen van $\mathbf{X}_{t-1}$ és $\mathbf{Y}_t$ között.

A hálózat ritkaságát (*sparsity*) az határozza meg, hogy mennyire erősen összekapcsolt a hálózat: ha sok él van jelen, a ritkaság alacsony; ha kevés él van jelen, a ritkaság magas. Egy csomópont szintjén a ritkaságot az *in-degree* (hány él mutat egy csomóponttra) és az *out-degree* (hány él mutat ki egy csomópontból) írja le. A statisztikai terminológiában az *in-degree* a változó $\mathbf{X}$ felé mutató késleltetett hatások számát, míg az *out-degree* a változó $\mathbf{X}$ -ből kiinduló késleltetett hatások számát jelenti.

2.1. A VAR modellek impulzusválasz-analízisének bevezetése

Ezen alfejezet Mohr (2020) alapján íródott.

Az impulzusválasz-analízis kulcsfontosságú lépés az olyan ökonometriai elemzésekben, amelyek vektor-autoregresszív (VAR) modelleket alkalmaznak. Elsődleges célja a modell változóinak alakulásának leírása egy vagy több változót érő sokk hatására. Ez a módszer-tan lehetővé teszi egyetlen sokk hatásának nyomon követését egy egyébként zajos egyenletrendszeren belül, így különösen hasznos eszközzé válik gazdaságpolitikai intézkedések értékelése során. Jelen alfejezetben az impulzusválasz-függvények fogalmába és értelmezésébe nyerünk betekintést, ahogyan azokat a VAR modellezési irodalomban általánosan alkalmazzák.

2.1.1. Előrejelzési hiba impulzusválasz

Mivel a VAR modellekben minden változó kölcsönösen hat egymásra, az egyedi együtthatóbecslések csak korlátozott információt nyújtanak a rendszer sokkra adott reakciójáról. A modell dinamikus viselkedésének jobb megértéséhez impulzusválaszokat (IR) alkalmaznak. Az impulzusválasz-függvények kiindulópontja a lineáris VAR modellek esetében azok mozgóátlag (MA) reprezentációja, amely egyben az előrejelzési hiba impulzusválasz (FE-IR) függvény is. Matematikailag az

$$\Phi_i = \sum_{j=1}^i \Phi_{i-j} A_j, \quad \text{ahol } i = 1, 2, \dots \quad (2.4)$$

Ebben az egyenletben:

$$\Phi_0 = I_K, \quad A_j = 0 \quad \text{ha } j > p$$

ahol K az endogén változók száma, p pedig a VAR modell késleltetési sorrendje. Az A_j mátrixok a $\text{VAR}(p)$ modell becslése során meghatározott autoregresszív együtthatókat

tartalmazzák. Ezek a mátrixok adják meg, hogy az egyes endogén változók hogyan hatnak egymásra saját és más változók korábbi értékein keresztül.

2.1.2. Az azonosítási probléma

Az FEIR-ek egyik hátránya, hogy nem használhatók a változók egyidejű reakcióinak értékelésére. Matematikailag ez azzal magyarázható, hogy Φ_i meghatározásához kizárólag az $\mathbf{A}_j$ együtthatómátrixokat használjuk, amelyek nem tartalmaznak információt az egyidejű összefüggésekről. Az utóbbiakra vonatkozó információ inkább a szimmetrikus szórás-kovariancia mátrix, Σ , nem diagonális elemeiben található.

Mivel a becsült variancia-kovariancia mátrix nem diagonális elemei nem egyenlők nullával, feltételezhetjük, hogy a VAR modellben lévő változók között egyidejű korreláció áll fenn. Ezt a korrelációs mátrix is megerősíti, amely megfelel Σ -nak.

Azonban ezek a mátrixok csak a hibák közötti korrelációt írják le, de nem derül ki belőlük, hogy a kauzalitások mely irányban hatnak. Az ilyen oksági kapcsolatok azonosítása a VAR elemzés egyik legfőbb kihívása.

Függetlenül attól, hogy milyen módszert alkalmazunk a lineáris VAR modell sokkjainak azonosítására, az egyidejű kapcsolatokkal kapcsolatos további információkat az FEIR-be bevihetjük azáltal, hogy megszorozzuk egy mátrixszal, $\mathbf{F}$ -fel, amely az egyidejű összefüggéseket írja le idősoraink között:

$$\Theta_i = \Phi_i \mathbf{F}$$

Az alábbiakban ismertetek néhány módszert $\mathbf{F}$ megtalálására, valamint a hozzájuk tartozó impulzusválaszokat.

2.1.3. Ortogonális impulzusválaszok

Egy gyakori megközelítés a VAR modell sokkjainak azonosítására az ortogonális impulzusválaszok (OIR) használata. Az alapötlet az, hogy a variancia-kovariancia mátrixot felbontjuk úgy, hogy

$$\Sigma = \mathbf{P}\mathbf{P}'$$

ahol $\mathbf{P}$ egy alsó háromszög mátrix pozitív diagonális elemekkel, amit gyakran Choleski-felbontással érhetünk el.

Az ehhez tartozó ortogonális impulzusválasz függvény:

$$\Theta_i^\circ = \Phi_i \mathbf{P}.$$

Vegyük figyelembe, hogy a Choleski-felbontás eredménye egy alsó háromszög mátrix, ezért a rendszer első sorában lévő változóinak érzékenysége egy másik változó sokkjára sosem lesz egyidejű, és a rendszer utolsó sorában lévő változója érzékeny lesz az összes többi változó sokkjára. Ezért az OIR eredményei érzékenyek lehetnek a változók sorrendjére, és ajánlott a fenti VAR modellt különböző sorrendekkel is becsülni, hogy megvizsgáljuk, mennyire befolyásolják az eredményeket.

Strukturális impulzusválaszok

A strukturális impulzusválaszok (SIR) már a VAR modell becslése során figyelembe veszik az azonosítási problémát. A strukturális vektor autoregresszív (SVAR) modell esetén:

$$\mathbf{A}_0 \mathbf{y}_t = \mathbf{v} + \sum_{i=1}^p \mathbf{A}_i \mathbf{y}_{t-i} + \boldsymbol{\epsilon}_t, \quad (2.5)$$

ahol $\boldsymbol{\epsilon}_t \sim \mathcal{N}(\mathbf{0}, \boldsymbol{\Omega})$, $\boldsymbol{\Omega}$ egy varianciákból álló diagonális mátrix, és $\mathbf{A}_0$ egy alsó háromszög mátrix, amely főátlóján egységek szerepelnek. Az ehhez tartozó strukturális impulzusválasz függvény:

$$\Theta_i^s = \Phi_i \mathbf{A}_0^{-1}. \quad (2.6)$$

Általánosított impulzusválaszok

Az ortogonális és strukturális impulzusválaszok korlátozottak, mivel vagy a változók sorrendjének megtalálásán, vagy a becsült strukturális paraméterek azonosításán alapulnak. Koop et al. (1996) egy másik típusú impulzusválasz függvényt javasoltak, az úgynevezett általánosított impulzusválaszokat (GIR). Ezek függetlenek a változók sorrendjétől, mivel integrálják az összes egyidejű sokk hatását is a válaszbba. Matematikailag ez a következő módon érhető el:

$$\Theta_i^g = \Phi_i \sigma_{jj}^{-\frac{1}{2}} \Sigma, \quad (2.7)$$

ahol σ_{jj} az j -edik változó varianciája.

Az általánosított impulzusválaszok (GIR) különösen hasznosak nagy rendszerek esetén, ahol a strukturális kapcsolatok nehezen azonosíthatók. Bár nem tekinthetők strukturális impulzusválaszoknak, pontos képet adnak a változó történeti fejlődéséről.

3. fejezet

A Diebold-Yilmaz 2012-es keretrendszer

A következő fejezet alapjául Diebold és Yilmaz (2012) cikke szolgált.

Diebold és Yilmaz (2009) bevezettek egy volatilitás-átterjedési mérőszámot, amely a vektorautoregresszióból származó előrejelzési hiba variancia dekompozícióján alapul. Ez a mérőszám alkalmas a hozamok átterjedésének mérésére, valamint az egyes eszközök vagy portfóliók hozamának volatilitásának értékelésére, akár adott országon belül, akár országok között, lehetővé téve a volatilitás-terjedési mintázatok feltárását. Bár ez a volatilitás-terjedési mérőszám értékes információkat szolgáltat, figyelmen kívül hagyja a „csoportdinamika” jelenségével kapcsolatos vitatható kérdéseket is. A „csoportdinamika” alatt azt értjük, hogy a Diebold–Yilmaz-féle mutató alapvetően kétoldalú kapcsolatok (pl. egy adott vállalat hatása egy másikra) mérésére szolgál, miközben nem tudja közvetlenül megragadni azokat az összetett mintázatokat, amelyek csoporton belüli vagy csoportok közötti volatilitás-átadási mechanizmusokat írnak le. Például egy pénzügyi szektoron belüli vállalathálózat esetén fontos lehet, hogy milyen belső struktúrák, klaszterek vagy alcsoportok alakítják a sokkátvitelt. A standard DY-mutató azonban nem alkalmas az ilyen hálózatszintű vagy klaszteralapú elemzésekre.

Vitatható kérdésként felmerül továbbá az is, hogy a mutató értelmezése érzékeny lehet a választott előrejelzési horizontra, a dekompozíció technikai részleteire (például ortogonális vs. generalizált sokkok alkalmazása), illetve a nem stacionárius idősorokra vonatkozó feltételezésekre is. Ezen kívül a mutató szimmetrikus kezelést alkalmaz, vagyis nem különböztet meg negatív és pozitív sokkokat, illetve nem ad választ arra, hogy egy sokk milyen gyorsan terjed át a rendszer más részeire.

A Diebold–Yilmaz-féle keretrendszer tehát bizonyos kontextusokban – például csoportos, hálózatszintű dinamika vagy aszimmetrikus sokkhatások esetén – korlátokba ütközik. Ezek a módszertani kihívások és gyakorlati alkalmazásbeli nehézségek indokolták a keret-

rendszer 2012-es továbbfejlesztését. Diebold és Yilmaz (2012) tanulmánya olyan elméleti és technikai megoldásokat javasol, amelyek célja a korábbi hiányosságok kezelése, különösen a generalizált FEVD alkalmazásával. Jelen fejezetben ezen továbbfejlesztett megközelítés főbb elemei kerülnek bemutatásra.

Először nézzük meg a módszertani korlátokat. A Diebold-Yilmaz keretrendszer a VAR modellek Cholesky-faktoros azonosítására épít, ami miatt a kapott variancia-dekompozíciók a változók sorrendjétől függhetnek. Egy olyan átterjedési mérőszám lenne ideális, amely független a változók sorrendjétől.

Másodszor, talán a legfontosabb problémaként emelhető ki, hogy a Diebold-Yilmaz mérőszám csupán az összesített átterjedéssel foglalkozik. Ez azt jelenti, hogy a mérőszám figyelembe veszi, hogyan terjednek ki a volatilitási hatások az „i” piacról más piacokra, valamint az összes többi piac hatását is, beleértve az „i” piacot is. Az összesített átterjedés tehát az összes kölcsönhatást vizsgálja, de nem tesz különbséget a hatások iránya között.

Ezzel szemben az irányított átterjedés arra összpontosít, hogy egy adott piac (például az „i” piac) közvetlenül hogyan hat egy másik piacra (például a „j” piacra). Ez lehetővé teszi, hogy részletesebben megértsük a különböző piacok közötti konkrét interakciókat és hatásokat. Szeretnénk tehát az irányított átterjedéseket is vizsgálni, hogy pontosabb képet kapjunk arról, mely piacok befolyásolják egymást és milyen mértékben.

Most térjünk át a gyakorlati szempontokra. A Diebold-Yilmaz keretrendszer kizárólag a különböző országokban található azonos típusú eszközök (például részvények) közötti átterjedés mérésére összpontosít. Ugyanakkor számos más érdekes lehetőség is létezik, például az egyes eszközök közötti átterjedés egy adott országon belül (mint például a harminc Dow Jones Industrials részvény az Egyesült Államokban), az eszközosztályok közötti átterjedés (például a részvény- és kötvénypiacok között az Egyesült Államokban), valamint különböző kombinációk is.

Különösen figyelemre méltó az eszközosztályok közötti átterjedés a 2007-2009-es globális pénzügyi válság fényében, amely a hitelpiacokról indult, majd átterjedt a részvényt piacokra. Érdeemes megjegyezni, hogy a Diebold-Yilmaz keretrendszer ezeket a tényezőket 2012 előtt még nem vizsgálta.

Diebold és Yilmaz (2012) ezeket a tartalmi és módszertani hiányosságokat pótolja. Ebben egy olyan általánosított vektorautoregresszív keret kerül bemutatásra, amelyben az előrejelzési hiba variancia dekompozíciói invariánsak a változók sorrendjére és az irányított átterjedés is figyelembevételre kerül. A következő alfejezetben erről lesz szó.

3.1. Az általánosított volatilitás-átterjedés és mérése

Ebben az alfejezetben a Diebold-Yilmaz átterjedési index általánosítása kerül bemutatásra, amely a variancia-dekompozíció fogalmán alapul egy N -változós vektor-autoregressziós (VAR) modellben. Míg a Diebold-Yilmaz keretrendszer alapvetően a teljes átterjedés mértékére koncentrál egy egyszerű VAR-modellben – ami a Cholesky-faktorokkal történő ortogonalizálás révén történik, és így potenciálisan függ az egyes változók sorrendjétől –, itt most az irányított átterjedés mérésére összpontosítunk egy általánosabb VAR-keretben, amely kiküszöböli az eredmények sorrendfüggőségét. A VAR-modellben az egyidejű kapcsolatok az ε - Σ -kovarianciamátrixban jelennek meg. A hibavariancia-dekompozíció során ennek Cholesky-felbontását alkalmazzák alapértelmezés szerint, amely azonban érzékeny a változók sorrendjére. Ezzel szemben Koop et al. (1996), valamint Pesaran és Shin (1998) módszere azt javasolja, hogy a hibavariancia-dekompozícióban ne a Cholesky-felbontást használjuk, hanem az OLS-becslés reziduumainak teljes kovarianciamátrixát. (lásd részletesen: 2.fejezet)

Tekintsünk egy kovariancia-stacionárius N -változós $Var(p)$ folyamatot:

$$x_t = \sum_{i=1}^p \phi_i x_{t-i} + \epsilon_t \quad (3.1)$$

ahol $\epsilon \sim \mathcal{N}(0, \Sigma)$ független normális eloszlású távolságok vektora. Ennek a folyamatnak a mozgó átlag reprezentációja:

$$x_t = \sum_{i=0}^{\infty} A_i * \epsilon_{t-i} \quad (3.2)$$

ahol A_i -k $N \times N$ együttható mátrixok és a következő rekurzió alapján képződnek:

$$A_i = \phi_1 A_{i-1} + \phi_2 A_{i-2} + \dots + \phi_p A_{i-p} \quad (3.3)$$

ahol A_0 az $N \times N$ -es identitás mátrix és $A_i = 0$ minden $i < 0$ esetén. A rendszer dinamikájának megértésében kulcsszerepet játszanak a mozgó átlag együtthatók, illetve ezek olyan transzformációi, mint az impulzusválaszfüggvények vagy a variancia dekompozíciók. Az impulzusválaszfüggvények egyes komponenseit nemcsak külön-külön lehet értelmezni, hanem aggregált formában is – például négyzetre emelve és időben összegezve. Ez a megközelítés kulcsfontosságú az előrejelzési hiba variancia dekompozíciók során, amelyeket az irodalomban FEVD (Forecast Error Variance Decomposition) néven ismerün. Ezeknek célja annak mérése, hogy egy adott változót érő sokk mekkora mértékben járul hozzá egy másik változó hibavarianciájához. Ilyen célokra használjuk az alábbi képletet:

$$\sum_{l=0}^Q (e'_i A_l P e_j)^2 \quad (3.4)$$

ahol e_i és e_j bázisvektorok, a P mátrix a VAR modell hibatag kovariancia mátrixának Cholesky-felbontása. Ez az ortogonális impulzusválaszok (OIR) négyzeteinek időbeli összegzése.

Az impulzusválaszfüggvények alapján számítható ki az ortogonális előrejelzési hiba variancia dekompozíciója (FEVD), amely azt mutatja meg, hogy az x_i változó előrejelzési hibájának mekkora hányada tulajdonítható az x_j -ből származó sokkoknak. Az ortogonális FEVD képlete a következő:

$$\theta_{ij}^{\text{OIR}} = \frac{\sum_{l=0}^n (e_i^\top A_l P e_j)^2}{\sum_{l=0}^n (e_i^\top A_l \Sigma A_l^\top e_i)} \quad (3.5)$$

A számlálóban az x_j -ből származó sokkok hatásainak négyzetei szerepelnek az x_i változóra vonatkozóan, míg a nevező az x_i összes előrejelzési hiba varianciáját adja. Az így kapott arány mutatja meg, hogy az x_j sokkjai milyen mértékben járulnak hozzá az x_i előrejelzési hibájához.

A Cholesky-faktorizáción alapuló azonosítási sémák ortogonalitást érnek el, azonban a variancia-összetételek a változók sorrendjétől függenek. Ezt a problémát megkerüljük, az általánosított VAR keret alkalmazásával Koop et al. (1996) és Pesaran és Shin (1998) alapján (továbbiakban KPPS), amely sorrendfüggetlen variancia dekompozíciót eredményez. Ahelyett, hogy a sokkokat ortogonalizálnánk, az általánosított megközelítés a korrelált sokkok hatását úgy kezeli, hogy a korábban megfigyelt hibák eloszlását veszi figyelembe, ezzel biztosítva a korrelált sokkok hatásának megfelelő értékelését. Mivel az egyes változók sokkjait nem ortogonalizáljuk, az előrejelzési hiba varianciájához való hozzájárulások összege (azaz a varianciabontási táblázat elemeinek sorösszege) nem feltétlenül egyenlő eggyel. A 3.5. képlet a *spillover* képlet, ahol nincsenek azonos idejű oda-vissza hatások (ortogonalizálás van). A 3.6 pedig a *connectedness* képlet, ahol ezeket az egyidejű hatásokat figyelembe vesszük (a kezdeti sokkok nem ortogonálisak).

3.1.1. Varianciahányadok

A varianciahányadokat úgy definiáljuk, mint az x_i előrejelzés H -lépésnyi előrejelzési hibavarianciájának azon részét, amely az x_i -re ható sokkoknak tulajdonítható, minden $i = 1, 2, \dots, N$ -re. Ezen felül, a keresztvariancia hányadokat vagy áttérjedéseket pedig az x_i előrejelzés H -lépésnyi előrejelzési hibavarianciájának azon részeként értelmezzük, amelyek az x_j -t érő sokkok következtében keletkeznek, ahol $i, j = 1, 2, \dots, N$ és $j \neq i$.

Jelöljük a KPPS H -lépésnyi előrejelzési hiba variancia dekompozíciókat $\theta_{ij}^g(H)$ -val minden $H = 1, 2, \dots$ esetén, az alábbi képlet alkalmazásával:

$$\theta_{ij}^g(H) = \frac{\sigma_{jj}^{-1} \sum_{h=0}^{H-1} (e_i' A_h \Sigma e_j)^2}{\sum_{h=0}^{H-1} (e_i' A_h \Sigma A_h' e_i)} \quad (3.6)$$

ahol Σ az ϵ hibavektor varianciamátrixa, σ_{jj} a j -edik egyenlet hibakifejezésének szórása, e_i a kiválasztási vektor, amelynek i -edik eleme egy, a többi pedig nulla. Ahogy korábban is már említésre került, a variancia dekompozíciós táblázat egyes sorainak összege nem egyenlő eggyel:

$$\sum_{j=1}^N \theta_{ij}^g(H) \neq 1 \quad (3.7)$$

Az átterjedési index számításánál a szórásdekompozíciós mátrix minden egyes elemét normáljuk a megfelelő sor összegével, a következőképpen:

$$\tilde{\theta}_{ij}^g(H) = \frac{\theta_{ij}^g(H)}{\sum_{j=1}^N \theta_{ij}^g(H)} \quad (3.8)$$

Ezáltal biztosítjuk, hogy a következő összefüggések teljesüljenek :

$$\sum_{j=1}^N \tilde{\theta}_{ij}^g(H) = 1$$

valamint

$$\sum_{j,i=1}^N \tilde{\theta}_{ij}^g(H) = N$$

3.1.2. Teljes volatilitás-átterjedés

A KPPS varianciadekompozícióból származó volatilitási hozzájárulások alapján meghatározhatjuk a teljes volatilitás-átterjedési indexet az alábbiak szerint:

$$S^g(H) = \left(\frac{\sum_{i,j=1, i \neq j}^N \tilde{\theta}_{ij}^g(H)}{\sum_{i,j=1}^N \tilde{\theta}_{ij}^g(H)} \right) \cdot 100 = \frac{\sum_{i,j=1, i \neq j}^N \tilde{\theta}_{ij}^g(H)}{N} \cdot 100 \quad (3.9)$$

Ez a mutató a KPPS módszer analógja a Cholesky-faktoron alapuló indexnek, amelyet Diebold és Yilmaz (2009) alkalmazott. A teljes átterjedési index azt mutatja meg, hogy a volatilitási sokkok átterjedése miként járul hozzá a vizsgált idősorok együttes előrejelzési hibavarianciájához.

3.1.3. Irányított-átterjedés

A teljes volatilitási átterjedési index önmagában is hasznos annak megértéséhez, hogy a volatilitási hatások révén milyen mértékben terjednek át a sokkok a főbb eszközosztályok között. A generalizált VAR megközelítés ugyanakkor lehetőséget nyújt az átterjedések irányának meghatározására is. Mivel a generalizált impulzusválaszok és varianciadekompozíciók függetlenek a változók sorrendjétől, az irányított átterjedéseket a generalizált varianciadekompozíciós mátrix normált elemeivel számítjuk ki. Az irányított volatilitási

átterjedéseket pedig úgy mérjük, hogy figyelembe vesszük az egyes i piacok által fogadott átterjedéseket, amelyeket a többi j piac továbbít.

$$S^g(H) = \left(\frac{\sum_{j=1, i \neq j}^N \tilde{\theta}_{ij}^g(H)}{\sum_{i,j=1}^N \tilde{\theta}_{ij}^g(H)} \right) \cdot 100 = \frac{\sum_{j=1, i \neq j}^N \tilde{\theta}_{ij}^g(H)}{N} \cdot 100 \quad (3.10)$$

Hasonló struktúrával meghatározhatjuk az irányított volatilitási átterjedést is, amely azt mutatja, hogy az i piac mekkora volatilitási hatást továbbít az összes többi j piacra.

$$S^g(H) = \left(\frac{\sum_{j=1, i \neq j}^N \tilde{\theta}_{ji}^g(H)}{\sum_{i,j=1}^N \tilde{\theta}_{ji}^g(H)} \right) \cdot 100 = \frac{\sum_{j=1, i \neq j}^N \tilde{\theta}_{ji}^g(H)}{N} \cdot 100 \quad (3.11)$$

Az irányított átterjedések halmaza a teljes átterjedések dekompozíciójaként is értelmezhető, amely azt mutatja, hogy egy adott forrástól származnak-e, vagy éppen oda irányulnak.

3.1.4. Nettó átterjedés

A nettó volatilitási átterjedést az i piacról a többi j piacra úgy határozzuk meg, hogy:

$$S_i^g(H) = S_i^{g, \text{to}}(H) - S_i^{g, \text{from}}(H). \quad (3.12)$$

A nettó volatilitási átterjedés egyszerűen az adott piacról származó bruttó volatilitási sokkok és a többi piactól érkező sokkok különbségeként értelmezhető.

3.1.5. Nettó páronkénti átterjedés

A nettó volatilitási átterjedés az előző egyenletben összefoglaló jelleggel mutatja meg, hogy egy adott piac nettó értelemben miként járul hozzá a többi piac volatilitásához. Szintén érdekes a nettó, páronkénti volatilitási átterjedések vizsgálata, amelyeket a következőképpen definiálunk:

$$\begin{aligned} S_{ij}^g(H) &= \left(\frac{\theta_{ij}^g(H)}{\sum_{k=1}^N \theta_{ik}^g(H)} - \frac{\theta_{ji}^g(H)}{\sum_{k=1}^N \theta_{jk}^g(H)} \right) \cdot 100 \\ &= \left(\frac{\theta_{ij}^g(H)}{N} - \frac{\theta_{ji}^g(H)}{N} \right) \cdot 100 \end{aligned} \quad (3.13)$$

A nettó páronkénti volatilitási átterjedés az i és j piac között egyszerűen a piaci i -ből a piaci j -be továbbított bruttó volatilitási sokkok és a piaci j -ből a piaci i -be továbbított sokkok különbségeként értelmezhető.

4. fejezet

A keretrendszer és más megközelítések korábbi alkalmazási területei a volatilitás-átterjedés vizsgálatában

Az elmúlt évtizedben Diebold és Yilmaz (2012) általánosított átterjedési indexe (DY átterjedési index), amely a Pesaran és Shin (1998), valamint Koop et al. (1996) által kidolgozott általánosított előrejelzési hibavariancia-felbontást alkalmazza, egyre nagyobb népszerűsége tett szert a kockázati átvitel elemzésében. A módszert számos kiterjesztésben alkalmazták, például a volatilitás átvitelének vizsgálatára, időben változó paraméterű VAR modellek keretében (Antonakakis et al. (2023), Ghosh et al. (2023)).

A DY átterjedési index népszerűsége annak intuitív és rugalmas jellegére vezethető vissza, amely alkalmassá teszi a hálózatelemzésre még a piacok instabilitása vagy átmeneti helyzetek során is. A modell egyik jelentős erőssége, hogy figyelembe veszi a volatilitás dinamikus természetét, lehetővé téve a változó piaci környezethez való alkalmazkodást, és számol a piaci (vagy hálózati) szereplők közötti kölcsönhatásokkal. Ezenkívül a módszer képes megkülönböztetni az irányított átterjedéseket, elősegítve a potenciális szisztemikus kockázatok fő forrásának azonosítását.

Kiemelendő a nettó átterjedési mátrix szerepe, amely hatékony eszközként szolgál a rendszerszinten fontos elemek vizualizálására egy adott vállalati halmazon belül. Összességében a DY átterjedési index széles körű alkalmazása elsősorban a fent említett statisztikai előnyöknek köszönhető (Huszár et al. (2023)).

4.1. Volatilitás-átterjedések mérése az amerikai eszközosztályok között

Diebold és Yilmaz (2012) az általánosított átterjedési indexet alkalmazta, hogy mérje a volatilitási átterjedéseket négy kulcsfontosságú amerikai eszközosztály között: részvények, kötvények, devizák és árucikkek. Ez különös jelentőséggel bír, mivel az eszközosztályok közötti átterjedések kiemelkedően fontosak voltak a 2007-ben kezdődött globális pénzügyi válság során. Diebold és Yilmaz (2012) különösen az S&P 500 indexet, a tíz éves amerikai kincstárjegy hozamát, a New York-i árutőzsdén jegyzett amerikai dollár index határidős ügyleteit, és a Dow-Jones/UBS árupiaci indexet vizsgálta. Az adatkészletük 1999. január 25. és 2010. január 29. közötti időszakot fedi le, összesen 2771 napi megfigyeléssel. Az irodalmi hagyományoknak megfelelően, amely legalább Parkinson (1980) munkájáig nyúlik vissza, a napi varianciát a napi legmagasabb és legalacsonyabb árak alapján becsülték meg. Egy adott piacon a napi varianciát az alábbiak szerint került kiszámításra:

$$\hat{\sigma}_{it}^2 = 0.361 [\ln(P_{it}^{\max}) - \ln(P_{it}^{\min})]^2 \quad (4.1)$$

ahol $P_{it}^{\max}$ a legmagasabb ár adott piacon az adott napon, és $P_{it}^{\min}$ a legalacsonyabb ár. Mivel $\hat{\sigma}_{it}^2$ a napi variancia becslése, a napi évesített napi százalékos szórás becslése:

$$\hat{\sigma}_{it} = \sqrt{100 \cdot \frac{365}{N} \cdot \hat{\sigma}_{it}^2} \quad (4.2)$$

A következő táblázatot volatilitás-átterjedési táblázatnak nevezzük.:

	Részvények	Kötvények	Nyersanyagok	Deviza	"From"
Részvények	88,76	7,28	0,34	3,62	11,24
Kötvények	10,17	81,49	2,69	5,65	18,51
Nyersanyagok	0,46	3,69	93,71	2,14	6,29
Deviza	5,66	6,99	1,59	85,76	14,24
"To"	16,29	17,95	4,63	11,41	
Összes átterjedés, sajátot is beleértve	105,0	99,4	98,3	97,2	
Teljes átterjedési index (50,3/400): 12,6%					

4.1. táblázat. Volatilitás átterjedési táblázat, négy eszközosztály. Forrás: Diebold és Yilmaz (2012)

A táblázatban az off-diagonális oszlopösszegek ("To") és a sorösszegek ("From") az irányított volatilitás-átterjedést mutatják, előbbi a más eszközosztályok felé irányuló, utóbbi a más eszközosztályoktól származó átterjedést fejezi ki. Ha a másoktól való hozzájárulásból kivonjuk a másokhoz való hozzájárulást megkapjuk a nettó volatilitás-átterjedést.

Ezen felül a teljes volatilitás-átterjedési index a táblázat jobb alsó sarkában található. Ez megközelítőleg az off-diagonális elemek összege (vagy a sorösszeg) arányosítva a teljes oszlopösszeggel (beleértve a diagonális elemeket is), százalékos formában kifejezve. A volatilitás-átterjedési táblázat egy közelítő input-output felbontást nyújt a teljes volatilitás-átterjedési indexről.

Először az irányított átterjedés (bruttó és nettó) értelmezéséből vonhatók le következtetések. A "To" sorból látható, hogy a négy eszközosztályból származó bruttó irányított volatilitás-átterjedések nem térnek el jelentősen egymástól. A "From" oszlopból ugyanakkor kitűnik, hogy a kötvénypiac a legnagyobb bruttó irányított volatilitás-átterjedésnek van kitéve (18,5%), amelyet a devizapiac követ (14,2%), ahol a más piacokból származó átterjedés az előre jelzett hiba variancia 14,2%-át magyarázza. A nettó irányított volatilitás-átterjedések közül a legnagyobb mértékű a részvénytőke más piacok felé irányuló átterjedése ($16,29\% - 11,24\% = 5,05\%$), míg a devizapiac inkább befogadóként jelenik meg ($11,41\% - 14,24\% = -2,8\%$).

A teljes (nem irányított) volatilitás-átterjedés lényegében az irányított volatilitás-átterjedések különböző komponenseinek egyetlen indexben való összesítését jelenti. Ez az érték a táblázat jobb alsó sarkában található, amely azt mutatja, hogy az egész mintaidőszak alatt átlagosan 12,6%-a a négy piac előre jelzett hiba varianciájának átterjedésből származik. A táblázat összefoglalása egyszerű: mind a teljes, mind az irányított volatilitás-átterjedések alacsonynak bizonyultak a teljes mintaidőszakban.

Számos érdekes tényre fény derült kutatásukban, többek között, hogy a kötvény- és részvénytőkepiacok voltak a legvolatilisabbak (nagyjából egyenlő mértékben), míg az árupiaci és devizapiaci volatilitás viszonylag alacsonyabb volt. A volatilitás dinamikája rendkívül tartósnak tűnt. És végül minden volatilitás magas volt ezen válság idején, különösen a részvény- és kötvénypiacok volatilitása mutatott jelentős ugrásokat. Az elemzés azt mutatja, hogy a 2007-es pénzügyi válság intenzitása fokozódásával a volatilitás kiemelkedően átterjedt a részvénytőkepiacról más piacokra. Ez különösen a Lehman Brothers csődje után vált nyilvánvalóvá. Mint fentebb említettem, vizsgáltam az amerikai részvénytőkepiacot (S&P 500), kötvénypiacot (10 éves államkötvény hozam), devizapiacot (amerikai dollár index) és árupiacot (Dow-Jones/UBS árupiaci index) elemezte. A 2007 és 2009 közötti időszakban a részvénytőkepiac és kötvénypiac volatilitása ugrásszerűen megnőtt, miközben az árupiaci és devizapiaci volatilitás mérsékeltebb maradt. A válság során a részvénytőkepiacról más piacokra történő volatilitás átadása egyre jelentősebbé vált. A részvénytőkepiac lett az egyik legfőbb forrása a volatilitás átterjedésének, és különösen a devizapiac szenvedett el jelentős hatásokat a Lehman Brothers bukása után. Az egész mintaperiódust tekintve a volatilitás átterjedés viszonylag alacsony volt, de a 2007-2009-es válság során hirtelen megugrott. Ez az átterjedési index a pénzügyi válság csúcspontjain meghaladta a 30%-ot is. A ku-

tatás bemutatja, hogy a válság hatására a volatilitás erőteljesen megjelent az amerikai részvényt piacon, és onnan gyorsan áttért más piacokra, különösen a devizapiacra.

4.2. Volatilitás-átterjedések mérése az európai olaj- és gáziparban

Huszár et al. (2023) tanulmánya a volatilitás átterjedésének dinamikáját vizsgálja az európai olaj- és gázipar különböző szegmensei között. A kutatás a Diebold-Yilmaz általánosított átterjedési indexet (DY spillover index) alkalmazva elemzi az iparág szereplőinek közötti kapcsolódásokat, mind normál piaci környezetben, mind extrém körülmények között.

Az elemzés az európai olaj- és gázipar fő szegmenseire koncentrál, amelyek az Upstream (feltárás és kitermelés), Midstream (szállítás és feldolgozás), Downstream (finomítás és marketing), valamint az Integrated Oil & Gas – IOG (integrált olaj- és gázipari) vállalatok. Ezen szektorok mellett a nyersanyagárakat, például a Brent olaj, földgáz és gázolaj piacait is vizsgálják. Az elemzés kiterjed a szektor szereplőinek részvényáraira, napi hozamaira- és volatilitására, azonban csak a volatilitást vizsgálja.

A kutatás központi helyszíne Európa, ahol az összesített piaci kapitalizáció több mint 90%-át reprezentáló, európai tőzsdéken jegyzett vállalatokat vizsgálják. Az elemzett vállalatok földrajzilag is széles körű lefedettséget biztosítanak, ideértve többek között az Egyesült Királyságot, Franciaországot, Németországot valamint Oroszországot. Az elemzés időhorizontja 2006. október 24-től 2022. június 30-ig tart. Ez az időszak magában foglalja a 2008-as globális pénzügyi válságot, az európai adósságválságot és a COVID-19 járvány időszakát, valamint Oroszország 2022-ben Ukrajna elleni invázióját, amelyek mind jelentős volatilitási események voltak.

A kutatás a Diebold-Yilmaz átterjedési indexet használta, amely általánosított előrejelzési hibavariancia-felbontáson alapul. Ez a módszer lehetővé teszi az időben változó volatilitáskapcsolatok elemzését. A dinamikus elemzésekhez gördülő ablakos technikát alkalmaztak, amely figyelembe veszi a piacok változó struktúráit és kapcsolatainak időbeli alakulását. Az elemzés során a statikus és dinamikus kapcsolódásokat is feltárták, figyelembe véve a különböző piaci szegmensek közötti volatilitás - terjesztést és befogadást.

Az eredmények szerint az upstream szektor a fő volatilitás - transzmitter az iparágban belül, különösen a piaci sokkok idején. Az integrált olaj és gázipari vállalatok (IOG), amelyek hagyományosan volatilitás – befogadók voltak, az utóbbi évek geopolitikai eseményei, például az orosz-ukrán háború hatására jelentős volatilitás-transzmitterekké váltak, ami rendszerszintű instabilitást okozhat. A kutatás eredményei szerint a Midstream és Downstream szektorok jellemzően a volatilitás befogadóiként működnek, míg a földgáz,

mint nyersanyag, jelentős szerepet játszik a volatilitás áttérjedésében. Ennek oka, hogy a földgáz nettó volatilitásterjesztőként viselkedik, ezáltal az energiaellátási rendszer egyik meghatározó kockázati tényezőjévé válhat.

A kutatás új megvilágításba helyezi az energiaellátási lánc sebezhető pontjait, amelyek kritikusak lehetnek a szabályozók és a befektetők számára a válságálló stratégiák kialakításában.

4.3. Nyersanyagárak volatilitása a Covid alatt

Mroua és Lamine (2024) tanulmánya a COVID-19 világjárvány időszakában vizsgálta a nyersanyagindexek diverzifikációs előnyeit, kiemelten kezelve a statikus és dinamikus kockázati áttérjedéseket. Az elemzés középpontjában a részvény-, kötvény- és nyersanyagpiacok közötti kapcsolatok feltárása állt, különös tekintettel az egyes eszközosztályok közötti volatilitás – áttérjedési mechanizmusokra.

Az elemzés során az S&P GSCI nyersanyag-alindexeit használták a nyersanyagpiacok reprezentálására, amelyek között az energia-, nemesfém-, ipari fém- és mezőgazdasági (gabonák, puha árucikkek, élőállat) szektorok egyaránt szerepeltek. A részvénytőkepiacokat az MSCI regionális indexei képviselték, amelyek az Egyesült Államok, Európa, a csendes-óceáni térség és a feltörekvő piacok fejlődését tükrözték. Az amerikai állampapírtőkepiacot az S&P U.S. Government Bond Index szimbolizálta, amely fontos referenciapontként szolgált a kötvénytőkepiac vizsgálatában.

A vizsgálat időbeli kerete 1998. január 2. és 2020. szeptember 16. közé esett, lehetővé téve a járvány előtti és alatti időszak összehasonlítását. Ez az időhorizont megfelelő alapot nyújtott a piaci turbulenciák és a normál időszakok közötti különbségek elemzésére. Az elemzés során alkalmazott módszertan magában foglalta a Diebold-Yilmaz általánosított variancia-felbontásán alapuló áttérjedési indexeket, amelyeket mind statikus, mind dinamikus környezetben használtak. A dinamikus elemzésekhez 50 napos mozgóablakos technikát alkalmaztak, amely lehetővé tette a piaci kapcsolatok időbeli változásának pontos nyomon követését. Emellett a volatilitási adatsorokat GARCH(1,1) modellel becsülték, amely a várható hozamok és volatilitások együttes modellezését oldja meg.

A kutatás eredményei rámutattak, hogy a részvénytőkepiacok szorosan összekapcsolódnak más piacokkal, és jellemzően nettó sokkterjesztőként viselkednek. Az amerikai és európai részvénytőkepiacok különösen meghatározó terjesztő szerepet játszanak a globális pénzügyi piacokon, míg a csendes-óceáni és feltörekvő piacok inkább sokkbefogadóként jelennek meg. A nyersanyagpiacok – az energiaszektor kivételével – szintén nettó sokkbefogadónak bizonyultak. A nemesfémek, különösen az arany és az ezüst, biztonságos menedékként szolgálnak válsághelyzetekben, és jelentős diverzifikációs előnyöket kínálnak a befektetők

számára.

Az amerikai állampapírpiac az elemzések szerint elsődleges sokkbefogadóként viselkedett, amely megerősítette annak szerepét, mint a kockázatkezelési stratégiák fontos eszköze. Ez különösen válsághelyzetekben vált kiemelkedően fontossá, amikor a befektetők biztonságosabb piacokra irányították tőkéjüket. A kutatás arra is rávilágított, hogy a nyersanyagok (az energia kivételével) és az amerikai állampapírok hatékony fedezeti eszközökként szolgálnak, különösen a COVID-19 világjárványhoz hasonló válságok idején.

Ezen megállapítások hozzájárulnak a pénzügyi piacok közötti kapcsolatok mélyebb megértéséhez, miközben iránymutatást nyújtanak a válságálló befektetési stratégiák kidolgozásához. A kutatás eredményei szerint a megfelelő diverzifikáció és a kockázatcsökkentési eszközök tudatos alkalmazása jelentősen javíthatja a befektetési portfóliók teljesítményét válsághelyzetekben.

4.4. Volatilitás-átterjedések mérése bankok és biztosítók között

Elyasiani et al. (2015) tanulmánya az Egyesült Államok, az Egyesült Királyság, az Európai Unió és Japán banki és biztosítási szektorainak hozam- és volatilitás-átterjedését vizsgálja. Külön figyelmet fordítanak a nagy és kis pénzintézetek közötti interakciókra, hogy feltárják a szektorok közötti kapcsolatok dinamikáját.

A vizsgálat időszaka 2003. január 1. és 2009. március 9. közé esik, amely magában foglalja a 2007 és 2009 között bekövetkezett pénzügyi válságot is. A válság 2007 április 2-án kezdődött az amerikai subprime hitelpiac összeomlásával, és 2009 március 9-én érte el mélypontját a globális tőkepiacokon.

A kutatók a multivariáns VAR-BEKK (Vector Auto Regression-Baba-Engle-Kraft-Kroner) modellt használták, amely lehetővé tette a hozamok és volatilitások közötti kapcsolatok időben változó dinamikájának vizsgálatát. Emellett kiterjesztett BEKK-MGARCH (Multivariate Generalized Autoregressive Conditional Heteroskedasticity) modellt is alkalmaztak, amely az időben változó kovariancia-mátrixok elemzésére alkalmas. Ez a modell figyelembe vette az aszimmetrikus volatilitási hatásokat, például azt, hogy a negatív sokkok erőteljesebb hatást gyakoroltak a volatilitásra, mint a pozitív sokkok. Az elemzések során különböző statisztikai teszteket alkalmaztak a hipotézisek validálására és a modell érvényességének ellenőrzésére.

A vizsgálat során a szerzők több empirikus hipotézist is megfogalmaztak a hozam- és volatilitás-átterjedések jelenlétére és azok változásaira vonatkozóan, különösen a 2007–2009-es pénzügyi válságot megelőző és az alatti időszakok tekintetében. A feltételezések között szerepelt, hogy a válság előtt nem figyelhető meg jelentős átterjedési hatás a vizsgált

régiók pénzügyi piacai között, továbbá, hogy ezek az esetleges kapcsolatok a válság hatására nem módosultak számottevően. A tanulmány célja volt annak vizsgálata is, hogy kimutatható-e érdemi volatilitás-átterjedés a banki és biztosítási szektorok között, illetve hogy e kapcsolatok intenzitása változott-e a válság következtében. Emellett a szerzők arra is keresték a választ, hogy az átterjedési hatások milyen irányban érvényesülnek valamint, hogy a hozamok és a volatilitás tekintetében mely régiók (az Egyesült Államok, az Egyesült Királyság, az Európai Unió és Japán) felől mutatkoznak egyoldalú hatások.

A fenti hipotézisek vizsgálatához a szerzők többféle statisztikai eljárást alkalmaztak. A log-likelihood arányteszt segítségével összevetették a korlátozott és a korlátozás nélküli modellek illeszkedését, annak érdekében, hogy eldöntsék, indokolt-e a feltételezett strukturális összefüggések beillesztése a modellbe. A Jarque–Bera teszt révén az adatok normalitását ellenőrizték, míg a Ljung–Box statisztika az autokorreláció meglétét vizsgálta, különösen a reziduumok időbeli függősége szempontjából. Az augmentált Dickey–Fuller teszt segítségével a hozamok és a volatilitások stacionaritását tesztelték, amely kulcsfontosságú a modell érvényességéhez. Végül, a probit regressziók alkalmazásával a kutatók a pénzügyi szektorok közötti kapcsolatok jelenlétét és irányát modellezték, különös figyelmet fordítva az intézményi hasonlóságokra és azok szerepére az átterjedési mechanizmusokban.

A felsorolt eljárások biztosították az eredmények robusztusságát, és hozzájárultak a pénzügyi szektorok közötti kölcsönös függőségek, valamint a volatilitás átterjedésének mechanizmusainak alaposabb megértéséhez.

Az eredmények rávilágítottak arra, hogy jelentős hozam- és volatilitás-átterjedések figyelhetők meg mind a banki, mind a biztosítási szektorok között. Ezek az átterjedési hatások a válság időszakában jelentősen felerősödtek. Különösen fontos megállapítás, hogy az amerikai pénzintézetek vezető szerepet játszottak a globális információáramlásban, mint az egyik fő információs központ. Az elemzés szerint az interakciók aszimmetrikusak voltak: ahogy azt már fentebb is említettem, a negatív sokkok nagyobb hatást gyakoroltak a volatilitásra, mint a pozitív sokkok.

A tanulmány továbbá azt is megállapította, hogy a pénzügyi intézmények közötti kapcsolatok erőssége jelentős mértékben függött az intézmények méretétől, tőkeáttételétől és finanszírozási sérülékenységétől.

5. fejezet

Az Európai Unió biztosítók

A következő két táblázatban láthatjuk az Európai Unió biztosítótársaságok közül a 15 legjobban teljesítőt a Reinsurance News (2024) kimutatásának legfrissebb, 2022-es adatai szerint bruttó díjbevétel (5.1. táblázat), valamint tőke nagysága (5.2. táblázat) alapján. Az adatok amerikai dollárban vannak megjelenítve.

Sorszám	Biztosító	Bruttó díjbevétel 2022 (US\$ ezer)
1	AXA	106,147,384
2	Allianz	100,568,547
3	Assicurazioni Generali	85,168,821
4	Munich Re	71,679,247
5	HDI Group (Talanx AG)	56,053,165
6	CNP Assurances	38,491,306
7	Crédit Agricole Assurances	37,720,412
8	BNP Paribas Cardif S.A.	26,983,420
9	Mapfre	26,202,383
10	Covéa	23,510,651
11	Achmea B.V.	22,516,079
12	SCOR	21,068,251
13	R+V Versicherung AG	19,931,129
14	Poste Italiane	18,724,606
15	Aéma Groupe B.V.	17,222,878

5.1. táblázat. Az Európai Unió legnagyobb biztosítói bruttó díjbevétel alapján (2022).
Forrás: Reinsurance News (2024)

Sorszám	Biztosító	Tőke (US\$ ezer)
1	Allianz	54,959,819
2	AXA	42,334,030
3	Munich Re	22,489,386
4	Covéa	19,599,082
5	NN Group N.V	18,972,317
6	CNP Assurances	18,279,687
7	Assicurazioni Generali	17,298,132
8	Achmea B.V	9,904,171
9	Groupe des Assurances du Crédit Mutuel	9,615,917
10	Poste Italiane	9,495,234
11	HDI Group (Talanx AG)	8,962,442
12	Crédit Agricole Assurances	8,652,803
13	Groupama Assurances Mutuelles	8,008,968
14	Mapfre	7,782,931
15	Aéma Groupe	5,480,345

5.2. táblázat. Az Európai Unió legnagyobb biztosítói tőke alapján (2022). Forrás: Reinsurance News (2024)

A biztosítótársaságok pénzügyi helyzetének és piaci jelentőségének értékelésére számos mutató használható. A két eltérő szempont alapján készült táblázat (rangsorolás) – a bruttó díjbevétel és a tőke nagysága – összehasonlításával elemezzük, hogy milyen különbségek figyelhetők meg a biztosítási piac szereplői között.

A díjbevétel szerinti rangsor a biztosítók által adott évben beszedett biztosítási díjak összességét mutatja, amely jól jelzi a társaság piaci részesedését és üzleti volumenét. Ezzel szemben a tőke szerinti rangsor a biztosítók pénzügyi stabilitását és tőkeerejét tükrözi, amely kulcsfontosságú a hosszú távú működés és a kockázatok fedezetének biztosítása szempontjából.

Az eltérő mutatók alapján készült rangsorolások nem feltétlenül tartalmazzák ugyanazokat a biztosítótársaságokat, mivel egy adott biztosító jelentős piaci részesedéssel bírhat alacsonyabb tőkeszint mellett, vagy éppen magas tőkével rendelkezhet kisebb díjbevétel mellett.

A két rangsor között számos átfedés található, amely azt jelzi, hogy bizonyos biztosítótársaságok mind a piaci jelenlét, mind a pénzügyi stabilitás szempontjából meghatározó

szereplők. Ide tartozik az Allianz, AXA, Munich Re, Covéa, CNP Assurances, Assicurazioni Generali, Achmea B.V., Poste Italiane, HDI Group, Crédit Agricole Assurances és Mapfre, ezek amelyek mindkét listán szerepelnek.

Ugyanakkor vannak olyan biztosítók, amelyek csak az egyik rangsorban jelennek meg, ami az eltérő üzleti stratégiára, kockázati profilra vagy a tőkeszerkezet sajátosságaira vezethető vissza.

Biztosítók, amelyek a díjbevétel szerinti rangsorban szerepelnek, de a tőke szerintiben nem:

- BNP Paribas Cardif S.A.
- SCOR
- R+V Versicherung AG

Ezek a biztosítók jelentős piaci jelenléttel bírnak a díjbevétel tekintetében, ugyanakkor relatíve alacsonyabb tőkével rendelkeznek. Ez több okra is visszavezethető: például a SCOR esetében viszontbiztosítói működésről van szó, amely más tőke megfelelési követelményekkel járhat, míg a BNP Paribas Cardif a bankbiztosítási szektorban aktív, ahol a termékstruktúra eltérhet a hagyományos biztosítóktól.

Biztosítók, amelyek a tőke szerinti rangsorban szerepelnek, de a díjbevétel szerinti listán nem:

- NN Group N.V.
- Groupe des Assurances du Crédit Mutuel
- Groupama Assurances Mutuelles
- Aéma Groupe

Ezek a biztosítók jellemzően stabil tőkehátteret tudhatnak magukénak, ugyanakkor a bevételeik nem érik el a legnagyobb szereplők szintjét. Az eltérés hátterében állhat, hogy egyes biztosítók konzervatívabb működési modellt követnek, kevesebb kockázatot vállalnak, vagy elsősorban tőkeerősségükkel biztosítják a hosszú távú stabilitásukat, valamint alapból nagy állománnyal rendelkeznek, így nem feltétlenül vannak a növekedésre, valamint új szerzésre ösztönözve. Ezen biztosítók lehet, hogy élet fókuszúak, ahol fontosabb a hosszútávú tőkekövetelmény. Az, hogy egy tiszta életbiztosító, az NN Group N.V. is jelen van a listán, az is erre utal.

A két rangsor közötti eltérések rávilágítanak arra, hogy a biztosítótársaságok piaci súlyának értékelésére többféle megközelítés alkalmazható. Míg a díjbevétel az üzleti aktivitást és a piaci részesedést mutatja, addig a tőke szintje a pénzügyi stabilitás és a kockázatok fedezésének képességére utal. A biztosítási piac sajátosságai miatt egyes társaságok

nagyobb hangsúlyt fektethetnek a díjbevétel növelésére, míg mások a tőke erősítésére helyezik a fókuszot.

Különösen az életbiztosítási ágazatban fontos megjegyezni, hogy a tőke nagyobb szerepet játszik, mint a rövid távú bevétel. Az életbiztosítási üzletág műveléséhez masszívabb tartalékokra van szükség, mivel itt a hosszú távú kockázatok kezelése és a tartalékok felhalmozása a legfontosabb. Ezért az életbiztosítási ágazatban erős társaságok esetében a tőke nagysága gyakran jobban meghatározó, mint a rövid távú bevétel. Ezzel szemben például kötelező gépjármű felelősségbiztosítás esetén, ahol évente sok új szerzés történik, a bevétel gyorsabban növekedhet, de a hosszú távú stabilitás szempontjából a tőke marad a kulcsfontosságú tényező. (Banyár (2016))

Az eredmények azt mutatják, hogy bár számos biztosító mindkét listán szerepel, bizonyos társaságok specializáltabb üzleti modellel működnek, ami eltérő rangsoroláshoz vezethet a különböző pénzügyi mutatók szerint. Az életbiztosítási ágazatban a tőkeerősítés és a hosszú távú stabilitás gyakran fontosabb, mint a rövid távú bevételi mutatók, míg más ágazatokban a piaci részesedés és az üzleti volumen lehet a meghatározó.

A következő fejezetben az elemzés során kizárólag olyan biztosítótársaságokat vettem figyelembe, amelyek részvényei szabadon forgalmazhatók a tőzsdén, illetve nyilvánosan elérhető részvényárfolyam-adatokkal rendelkeznek. Ez azért volt szükséges, mert a volatilitás-összefonódás (volatility connectedness) elemzése során napi záróárfolyamokat használtam fel, amelyeket csak a tőzsdén jegyzett társaságok esetében lehet megbízhatóan beszerezni. Ebből adódóan több jelentős biztosítótársaság is kimaradt az elemzésből, mivel nem feleltek meg ezen feltételeknek.

A **Groupama Assurances Mutuelles** egy olyan kölcsönös biztosítói csoport, amelynek tulajdonosai kizárólag regionális kölcsönös biztosítók. A társaság zárt tulajdonosi szerkezete kizárja, hogy részvényeit a tőzsdén nyilvánosan lehessen kereskedni, így árfolyamadatai nem állnak rendelkezésre. (Groupama Assurances Mutuelles (2025))

A **CNP Assurances** korábban tőzsdén jegyzett társaság volt, azonban 2022-ben a La Banque Postale 100%-os tulajdonrészt szerzett benne, aminek következtében kivonták a párizsi tőzsdéről. A vállalat jelenleg zártkörű tulajdonban van, ezért részvényeinek árfolyamadatai a nyilvános piacon nem érhetők el. (CNP Assurances (2025))

A **Covéa** szintén egy kölcsönös biztosítói csoport (SGAM), amely nem rendelkezik nyilvánosan forgalmazott részvényekkel. A csoport tagjai kizárólag kölcsönös biztosítók, amelyek közötti kapcsolat szoros együttműködésen alapul, és nem a piaci tőzsdei kereskedelemre épül. (Covéa (2025))

Az **Achmea B.V.** egy zártkörű részvénytársaság (Besloten Vennootschap, B.V.) formában működik, ami a holland jogrendszerben szintén zárt tulajdonosi szerkezetet jelent. A részvények nem kerültek nyilvános forgalomba, így az árfolyamokhoz nem lehet hozzá-

férni. (Achmea (2025))

Az **R+V Versicherung AG** a német Raiffeisen- és Volksbanken csoport központi biztosítója, amely szintén zártkörű társaságként működik, és nem bocsát ki tőzsdén kereskedett részvényeket. (R+V Versicherung AG (2023))

Az **Aéma Groupe** egy SGAM típusú biztosítói csoport Franciaországban, amely szintén kölcsönös biztosítók együttműködésén alapuló struktúrában működik. Részvényei nem elérhetők a nyilvános tőzsdén, és így árfolyamadatai nem állnak rendelkezésre. (Aéma Groupe (2024))

Végül a **Groupe des Assurances du Crédit Mutuel** (GACM) esete is hasonló: bár részvénytársasági formában (azaz francia jog szerinti 'Société Anonyme'-ként) működik, részvényei kizárólag a Banque Fédérative du Crédit Mutuel tulajdonában vannak, így a társaság zártkörű működése kizárja a nyilvános árfolyamkereskedelmet. (Groupe des Assurances du Crédit Mutuel (2024))

Tehát azok a társaságok, amelyek nem rendelkeznek szabadon kereskedhető részvényekkel, vagy a közelmúltban zártkörűvé váltak, technikai okokból nem szerepeltek a volatilitás-áttérjedés elemzésében, mivel nem álltak rendelkezésre az elemzéshez szükséges rendszeres és megbízható piaci adatok. Ezeknek megfelelően a következő fejezetben a modellt a bruttó díjbevétel alapú elemzéshez a következő biztosítótársaságokra építettem fel: AXA SA , Allianz SE, Assicurazioni Generali S.p.A., Münchener Rückversicherungs-Gesellschaft AG, Talanx AG, Crédit Agricole S.A., BNP Paribas S.A., Mapfre S.A., Scor SE, Poste Italiane S.p.A.. A tőke alapú elemzéshez pedig a következőkre: Allianz SE, AXA SA, Münchener Rückversicherungs-Gesellschaft AG, NN Group N.V., Assicurazioni Generali S.p.A., Poste Italiane S.p.A., Talanx AG, Crédit Agricole S.A., Mapfre S.A..

6. fejezet

A részvényárfolyamok volatilitás terjedése az Európai Unió biztosítótársaságok között

Ebben a fejezetben a bemutatott módszertant alkalmazom az 5. fejezetben ismertetett biztosítótársaságokra, melynek segítségével a részvényárfolyamuk volatilitás terjedését tudjuk elemezni. Elsőként a modellt a bruttó díjbevétel alapján rangsorolt Európai Unió biztosítótársaságokra mutatom be, majd utána a tőke alapján rangsoroltakét.

6.1. Az adatok bemutatása

Az adatok a Yahoo! Finance adatbázisából származnak. A lekérdezett adatok tartalmazzák az egyes részvények nyitó-, záró-, legalacsonyabb- és legmagasabb árfolyamait, 2018 január elseje és 2024 december 31-ig terjedő időintervallumban, napi bontásban.

A részvény i -re vonatkozó napi szórásnégyzet (volatilitás) t időpontban a következő képlet alapján kerül becslésre (lásd a 4. fejezetet) :

$$\hat{\sigma}_{it}^2 = 0.361 [\ln(P_{it}^{\max}) - \ln(P_{it}^{\min})]^2. \quad (6.1)$$

Ez a Parkinson-féle becslés (Parkinson (1980)) hatékony eszköz a volatilitás mérésére, amennyiben az eszköz árfolyama egy adott napon belül ténylegesen ingadozik, vagyis van eltérés a minimum és maximum árak között. Zárt végű alapok esetén azonban gyakran előfordul, hogy az adott napi nyitó-, záró-, minimum- és maximumár megegyezik, mivel ezen eszközök nem feltétlenül rendelkeznek aktív, napon belüli kereskedéssel. Ilyen esetekben a fenti képlet alapján számított volatilitás értéke nulla lenne, amely nem tükrözi a valós piaci kockázatot vagy árfolyam-ingadozást.

A probléma áthidalása érdekében a becslést módosítanunk szükséges úgy, hogy a napi maximum árat az adott napi értékből (t), míg a minimum árat az előző napi ($t - 1$) értékből vegyük. Ennek megfelelően a volatilitás becslése a következő formát ölti:

$$\sigma_{it}^2 = 0.361 \left[\ln(P_{i,t}^{\max}) - \ln(P_{i,t-1}^{\min}) \right]^2. \quad (6.2)$$

ahol $P_{i,t}^{\max}$ és $P_{i,t-1}^{\min}$ rendre az adott részvény adott napi legmagasabb ára, illetve az előző napi legalacsonyabb ára.

Ez a módszer lehetővé teszi, hogy a napi szinten állandó árfolyamok mellett is érzékeljük a két nap közötti ármozgásokat, így pontosabb becslést nyerhetünk az eszköz tényleges volatilitásáról. Különösen hasznos ez olyan esetekben, amikor az árak ritkán változnak napon belül, de a napi záróárak mégis tükröznék hosszabb távú ingadozásokat.

Mivel a volatilitás eloszlása gyakran torz, szokás logaritmikus volatilitást alkalmazni, amely közelítőleg normál eloszlású. Azonban nullához közeli értékek esetén a természetes logaritmus használata problémás lehet, ezért a módosított hiperbolikus szinusz inverzét használjuk:

$$\sinh^{-1}(x) = \log(2x) \quad (6.3)$$

Így a módosított volatilitás az alábbi képlet alapján számolható ki, a dolgozatban ezt a képletet használtam:

$$\sigma_{it} = \sinh^{-1} \left(\sqrt{252 \cdot \sigma_{it}^2} \right) \quad (6.4)$$

ahol a 252-es szorzó az évesítés célját szolgálja. (Sayed (2020))


A következő európai biztosítótársaságok részvényárfolyamait kérdeztem le a 5. fejezetnek megfelelően:

- **CS.PA** – AXA SA (Franciaország),
- **ALV.DE** – Allianz SE (Németország),
- **G.MI** – Assicurazioni Generali S.p.A. (Olaszország),
- **MUV2.DE** – Münchener Rückversicherungs-Gesellschaft AG (Németország),
- **TLX.DE** – Talanx AG (Németország),
- **ACA.PA** – Crédit Agricole S.A. (Franciaország),
- **BNP.PA** – BNP Paribas S.A. (Franciaország),
- **MAP.MC** – Mapfre S.A. (Spanyolország),

- **SCR.PA** – Scor SE (Franciaország),
- **PST.MI** – Poste Italiane S.p.A. (Olaszország).

Az elemzett időszak 2018. január 1-jétől 2024. december 31-ig tart, amely lefedi az Európai Unió biztosítási szektorában tapasztalható különböző piaci ciklusokat, 2018-2020 közötti pénzügyi válsággal nem terhelt időszakot, majd 2020-2022 közötti COVID válság alatti időszakot, végül pedig a 2022-2024 közötti orosz-ukrán háború időszakát.

A 6.1. ábrán bemutatott napi volatilitásokat a 6.1. táblázat foglalja össze, amely az évesített volatilitási értékeket tartalmazza:



6.1. ábra. A logaritmikus volatilitás

6.1. táblázat. Részvények évesített volatilitásának statisztikai jellemzői

Részvény	Megfigyelések	Átlag	Medián	Szórás	Minimum	Maximum
G.MI	1769	0,1586749	0,1247415	0,1379000	0	1,558677
CS.PA	1769	0,1758885	0,1357214	0,1610263	0	1,850402
MUV2.DE	1769	0,1665224	0,1287116	0,1524866	0	1,548215
MAP.MC	1769	0,1856736	0,1486146	0,1598914	0	1,555984
TLX.DE	1769	0,1724680	0,1340728	0,1580428	0	1,581563
PST.MI	1769	0,1878200	0,1469159	0,1690301	0	1,679769
BNP.PA	1769	0,2294247	0,1853351	0,1946936	0	1,704503
ACA.PA	1769	0,2165774	0,1700404	0,1913325	0	1,774412
ALV.DE	1769	0,1535432	0,1147702	0,1450909	0	1,599191
SCR.PA	1769	0,2402703	0,1897971	0,2064275	0	1,935780

A 6.1 ábra szemléletesen mutatja be a vizsgált részvények napi logaritmikus volatilitásának alakulását a 2018.01.03 és 2024.12.27 közötti időszakban. Az ábrán jól látható, hogy a részvények többsége esetében a volatilitás időszakosan megnövekedett, különösen a 2019-es év elején és a 2020-as év tavaszán, amely a COVID-19 világjárvány pénzügyi piacokra gyakorolt hatásával magyarázható. Érdeemes megjegyezni, hogy az orosz–ukrán háború kitörése (2022 februárja) nem okozott érdemi kiugrást a vizsgált biztosítótársaságok volatilitásában. Ennek egyik lehetséges oka, hogy e társaságok többségének nincs jelentős üzleti jelenléte a közép- és kelet-európai régióban, így közvetlen kitettségük az érintett térségek gazdasági és geopolitikai kockázataival szemben korlátozott maradt.

A vizualizáció alapján megfigyelhető, hogy a *SCR.PA* (Scor SE) részvény volatilitása a legtöbb időszakban kiemelkedik a többi részvényhez képest, amely összhangban van az 6.1. táblázatban bemutatott évesített volatilitási értékekkel is. A *SCR.PA* rendelkezik a legmagasabb átlagos volatilitással (0,2403), valamint a legnagyobb szórással (0,2064), és a legmagasabb extrém értékkel (1,9358) is.

Ezzel szemben az *ALV.DE* (Allianz) részvény jellemzően alacsonyabb volatilitást mutat, amely szintén megerősíti a táblázat alapján levont következtetést: ez a részvény rendelkezik a legalacsonyabb átlagos volatilitással és a legkisebb szórással a vizsgált minta alapján.

Az ábra egyértelműen kiemeli az időszakos volatilitási klasztereket, valamint a részvények közötti különbségeket, ami megalapozza a további empirikus elemzéseket, például a volatilitás terjedésének (*spillover*) vagy a kapcsolati hálózatok (*connectedness*) vizsgálatát.

6.2. Teljes mintaelemzés

6.2.1. Alapvető idősoros modellek: $\text{VAR}(p)$, $\text{MA}(q)$, impulzus-válaszfüggvény, előrejelzési hiba variancia

A *spillover* és a *connectedness* mutatók azt mérik, milyen mértékű kapcsolat figyelhető meg a részvények között a volatilitásuk alapján.

A kapcsolatok számszerűsítésére négy lépéses módszertant alkalmazok:

Első lépésként egy VAR modellt becslünk. Ebben a modellben N darab részvény volatilitásváltozóját (σ_i) vizsgáljuk egyszerre, p darab késleltetési lépés figyelembevételével. (3.1. képlet) Az optimális késleltetési rend kiválasztása információs kritériumok alapján történt, a BIC szerint $p = 1$ bizonyult legmegfelelőbbnek. Az BIC egy konzervatívabb információs kritérium, amely nagyobb büntetést alkalmaz a modell paramétereinek növekedésére, így csökkenti a túlilleszkedés kockázatát. Ez különösen előnyös lehet pénzügyi idősorok esetében, ahol a túlzottan komplex modellek instabilitáshoz vezethetnek.

A második lépésben ezt a VAR modellt átalakítjuk egy mozgóátlag (MA) alakra, amely a sokkhatások időbeli eloszlását teszi láthatóvá (3.2. képlet)

A harmadik lépés az impulzus-válasz függvények meghatározása. Itt azt mérjük, hogy ha egy adott részvény volatilitásában hirtelen egységnyi változás történik, akkor ez milyen mértékben hat egy másik részvény volatilitására a következő napokban. (3.4. egyenlet)

Végül, a negyedik lépésben az egész rendszerre kiterjedően kiszámítjuk az előrejelzési hiba variancia dekompozícióját (FEVD). Ez megmutatja, hogy egy adott részvény volatilitásának jövőbeli előrejelzési hibája milyen arányban származik más részvények sokkaiból (Ezt a *spillover* index esetén a 3.5. képlettel, a *connectedness* index esetén 3.6. képlettel számoljuk)

6.2.2. Teljes mintás spillover tábla

1. lépés: Vektor Autoregresszió (VAR)

A Diebold–Yilmaz-féle módszertanban a *spillover* és a *connectedness* index közötti egyik lényeges különbség az azonos idejű kapcsolatok kezelésében rejlik. A *Spillover* index az ortogonális impulzusválaszfüggvényeken (Orthogonalized Impulse Response, OIR) alapul, amelyek meghatározása során a hiba-kovariancia mátrix Cholesky-felbontását alkalmazzuk. Ez a módszer kizárólag a hiba-kovariancia mátrix alsó háromszögét veszi figyelembe, így az elemzésből kimaradnak az azonos időpontban jelentkező kölcsönhatások.

Ezzel szemben a *connectedness* index a teljes hiba-kovariancia mátrixot használja, és ennek következtében képes megragadni azokat a kapcsolódásokat is, amelyek ugyanabban az időpillanatban (t) történnek. Ez azt jelenti, hogy ha például egy sokk éri az X változót,

amely azonnal hatással van az Y változóra, akkor az Y is visszahatást gyakorolhat X -re még az adott időpontban. Nem szükséges megvárni a következő időszakot $(t + 1)$ ahhoz, hogy ez a kölcsönös kapcsolat érvényesüljön. Ezt a szimultán visszacsatolást a *connectedness* index figyelembe veszi, míg a *Spillover* index – az ortogonális sokkokkal való számítás miatt – nem. A korrelált hibákkal dolgozó modell becslése egyszerűen megvalósítható azáltal, hogy a vizsgálni kívánt változókat bevisszük egy VAR modellbe.

Ha azt szeretnénk, hogy a modellben szereplő hibatagok függetlenek legyenek, akkor a VAR modell szerkezetét úgy kell alakítani, hogy ez a feltétel teljesüljön. Ezt nevezzük strukturális VAR (SVAR) modellnek, amelyben előzetes feltételezésekkel határozzuk meg, hogyan függenek össze a változók közötti sokkok. (lásd: 2.1.3. alfejezet)

Ebben a vizsgálatban egy olyan megkötetést alkalmaztam, ahol a sokkok sorrendjét egy alsó háromszög alakú mátrix írja le, amelynek főátlójában 1-es értékek szerepelnek. Ez a VAR hibatagok Szigma kovariancia mátrixának Cholesky dekompozíciója (a P mátrix a korábbi képletekben). Ez azt jelenti, hogy az első változó azonnal hathat a többire, de ő maga csak késleltetve reagál, a második már csak az utána következőkre hat közvetlenül, és így tovább. Ez a megközelítés összhangban áll a Sims-féle strukturális azonosítási stratégiával, amely egy széles körben elfogadott módszer a VAR modellekben rejlő ok-okozati viszonyok vizsgálatára.

2. lépés: Mozgóátlagos (MA) reprezentáció

Általánosságban elmondható, hogy bármilyen p rendű autoregressziós (AR) modell átalakítható egy q rendű mozgóátlag (MA) reprezentációvá, amennyiben az AR modell paraméterei bizonyos stabilitási feltételeknek megfelelnek, például ha az értékük -1 és 1 közé esik. Ez az átalakítás teszi lehetővé, hogy az idősor múltbeli sokkjainak hatását expliciten vizsgálni tudjuk az idő előrehaladtával.

Az R nyelv tartalmaz egy függvényt, amely képes ezt az átalakítást végrehajtani a megadott q MA-rend alapján — ami jelen dolgozatban: $q = 10$.

A mozgóátlag-reprezentáció során meghatározásra kerülnek az MA együtthatók, amelyek azt mutatják meg, hogy egy korábbi időpontban bekövetkezett sokk milyen erővel és időbeli eloszlással hat a vizsgált változókra. Ezzel együtt megkapjuk a VAR modellből származó hibatagokat is, amelyek a későbbi impulzus-válasz és előrejelzési hiba dekompozíciós elemzések alapját képezik.

3. lépés: Impulzus-válasz függvény (IRF)

Az impulzus válaszfüggvény gyakorlati megvalósítása során először a becsült SVAR modell reziduálisainak kovariancia-mátrixán végeztem el a Cholesky-dekompozíciót, majd a mozgóátlag reprezentációhoz szükséges együtthatókat számítottam ki. Ezt követően kiszámítottam az impulzus-válasz függvényeket, valamint az ezekre épülő előrejelzési hiba variancia dekompozíciós mátrixot (FEVD), amely megmutatja, hogy az egyes részvények

volatilitása milyen mértékben függ más részvények sokkjaitól.

4. lépés: Előrejelzési hiba variancia dekompozíció (FEVD)

A mozgóátlag (MA) reprezentáció együttthatóinak minden egyes késleltetését megszorozzuk a Cholesky-dekompozíció során kapott mátrixszal, hogy meghatározhassuk az előrejelzési hiba variancia dekompozícióját (FEVD). A számítás során az MA együttthatómátrix adott sorát választjuk ki, amely a j változóra vonatkozik, majd ezeket megszorozzuk azokkal a sokkokkal, amelyek a i változóból származnak. (3.5.képlet) A 6.2 tábla a spillover táblát mutatja.

6.2. táblázat. Volatility Spillovers

	G.MI	CS.PA	MUV2.DE	MAP.MC	TLX.DE	PST.MI	BNP.PA	ACA.PA	ALV.DE	SCR.PA	From
G.MI	71	6	1	7	0	4	0	3	2	5	29
CS.PA	3	72	1	7	0	4	0	5	2	6	28
MUV2.DE	3	5	69	9	0	3	0	3	2	6	31
MAP.MC	2	6	1	75	0	3	0	5	3	5	25
TLX.DE	3	7	1	8	66	4	0	4	1	5	34
PST.MI	1	13	1	7	1	67	0	4	2	5	33
BNP.PA	1	8	2	11	0	5	55	7	4	7	45
ACA.PA	1	8	2	10	1	5	0	64	3	5	36
ALV.DE	2	4	2	6	0	3	1	5	72	4	28
SCR.PA	1	8	2	9	0	3	0	2	3	66	34
To	16	66	14	75	3	35	3	38	25	48	32

A táblázat a részvények közötti volatilitási áttérjedés mértékét mutatja, százalékos formában. Az egyes sorok azt mutatják, hogy az adott részvény volatilitásának mekkora hányadát magyarázzák más részvények sokkjai (*From*), míg az oszlopok végén szereplő értékek (*To*) azt jelzik, hogy az adott részvény milyen mértékben járul hozzá más részvények volatilitásához.

A diagonális elemek (pl. G.MI saját magára 71%, CS.PA önmagára 72% stb.) az önmagyarázat arányát jelzik, vagyis azt, hogy a részvény volatilitásának mekkora része vezethető vissza a saját sokkjaira. Ezek az értékek jellemzően 70% fölöttiek, ami azt mutatja, hogy a volatilitást elsődlegesen a részvény saját piaci mozgásai határozzák meg.

Az *From* oszlopban szereplő értékek alapján látható, hogy a legnagyobb befolyás más részvények felől a *BNP.PA* esetében figyelhető meg (45%), vagyis ennek a részvénynek a volatilitása reagál leginkább más részvények mozgására. Ehhez képest például a *G.MI*, *MAP.MC* és *ALV.DE* részvények volatilitása elsősorban belső hatásokból ered (kevesebb, mint 30% magyarázható külső sokkokkal), ami viszonylag elszigeteltebb piaci pozícióra utalhat.

A *To* sor értékei alapján elmondhatjuk, hogy kiemelkedik a *MAP.MC*, ez a szereplő

bír a legnagyobb átterjesztési hatással (75%), valamint a *CS.PA* és *SCR.PA*. Ezek a részvények tehát jelentős forrásai a piaci volatilitásnak.

A vizsgált részvények volatilitása részben egymásba ágyazott rendszerként működik: egyes részvények (mint a *SCR.PA* vagy *CS.PA* valamint *MAP.MC*) központi szerepet töltenek be a sokkok terjedésében, míg mások inkább lokálisan, saját eseményeik mentén reagálnak.

A táblázat jobb alsó sarkában szereplő érték azt mutatja, hogy a rendszerben vizsgált részvények volatilitásának átlagosan 32%-a más részvények sokkjainak tulajdonítható. Ez az arány a soronkénti *From* értékek átlaga.

6.3. Teljes minta szerinti connectedness tábla

A *connectedness* mutató számítása hasonló lépéseket igényel, azonban az IRF (impulzusválaszfüggvény) egyidejű sokkjait ebben az esetben már nem feltételezzük ortogonálisnak. Ennek eléréséhez a számlálóban szereplő alsó háromszög mátrixot, P -t a reziduumok kovarianciamátrixával helyettesítjük. Az általánosított FEVD egyenlet a: (3.6. képlet)

A 6.3 tábla a connectedness táblát mutatja.

6.3. táblázat. Volatility Connectedness

	G.MI	CS.PA	MUV2.DE	MAP.MC	TLX.DE	PST.MI	BNP.PA	ACA.PA	ALV.DE	SCR.PA	From
G.MI	9.47	8.84	7.85	8.74	7.52	10.51	13.44	13.29	6.83	13.52	90.53
CS.PA	6.65	11.83	8.20	8.39	7.84	9.00	13.92	13.57	7.28	13.34	88.17
MUV2.DE	6.23	8.90	11.93	8.85	8.74	8.60	12.31	11.99	7.49	14.95	88.07
MAP.MC	6.31	8.35	7.82	13.86	7.54	8.79	13.75	13.74	6.47	13.37	86.14
TLX.DE	6.15	8.69	9.11	8.70	12.05	8.83	12.27	12.25	7.26	14.69	87.95
PST.MI	7.31	7.97	7.62	8.32	7.20	14.99	13.43	13.48	6.61	13.07	85.01
BNP.PA	6.39	8.64	7.22	11.00	6.85	8.90	18.72	15.41	6.39	12.82	81.28
ACA.PA	6.35	8.50	7.07	10.01	6.82	9.20	15.98	18.55	6.37	12.51	81.45
ALV.DE	6.50	9.41	8.86	8.62	8.01	9.12	13.31	13.18	13.05	13.36	90.38
SCR.PA	5.77	7.67	8.13	7.99	7.79	7.98	11.90	11.55	5.97	25.26	74.74
To	57.66	76.95	71.88	76.83	68.29	80.94	120.31	118.46	60.66	121.74	85.37

A 6.2. táblázat a volatilitási sokkok százalékos megoszlását mutatta, vagyis azt, hogy az egyes részvények volatilitásának mekkora hányada származik saját, illetve más részvények sokkjaiból. Ezzel szemben a 6.3. táblázat nem a százalékos arányokat, hanem a kapcsolatok intenzitását mutatja meg: azt, hogy egy sokk milyen mértékű hatást gyakorol más részvények jövőbeli volatilitására. Ez a megközelítés nemcsak az átterjedés arányát, hanem annak erősségét is figyelembe veszi, így mélyebb betekintést nyújt a piaci kapcsolatok dinamikájába.

A 6.3. táblázat cellái tehát azt mutatják, hogy a sorban szereplő részvény volatilitásának mekkora részét befolyásolja az oszlopban szereplő részvény sokkja. A diagonális elemek továbbra is az önmagyarázatot jelentik, míg a sor- és oszlopösszegek (*From* és *To*) a bejövő és kimenő kapcsolatok összértékét tükrözik.

Az *From* oszlop értékei alapján megfigyelhető, hogy a legkisebb külső hatás a *SCR.PA* (Scor SE) részvényre érkezik, amelynek volatilitása 74,74%-ban más részvények sokkjaira vezethető vissza. Ez arra utal, hogy ez a részvény a legkevésbé érzékeny a piac többi szereplőjének mozgásaira. Ez az érték arányként, kvázi százalékként értelmezhető. Ezzel szemben a *G.MI* (Assicurazioni Generali) és az *ALV.DE* (Allianz) részvények volatilitásának több mint 90%-át más részvények sokkjai magyarázzák, tehát ezek a részvények jóval érzékenyebbek a külső sokkokra.

A *To* sor adatai a kisugárzott kapcsolatok mértékét mutatják. Itt a *SCR.PA* a 121,74%-os értékével, valamint *BNP.PA* a 120,31%-os értékével kiemelkedik, ami azt jelenti, hogy jelentős forrásaik más részvények volatilitási változásainak. Szintén figyelemre méltó az *ACA.PA* (Crédit Agricole), amely egyaránt erős kapcsolódási hatással bír (118,46%).

A teljes rendszer szintjén a kapcsoltság átlagos mértéke 85,37%, ami jelentős piaci integrációra utal. Ezt az értéket úgy kapjuk meg, hogy a mátrix főátlóján kívüli értékek összegét osztjuk minden elem összegével. Ebből az értékből arra következtethetünk, hogy a részvények volatilitása nagyrészt összehangoltan mozog, így a sokkok gyorsan és könnyen végighullámoznak a biztosítási piacon.

6.3.1. Teljes mintás FEVD hálózatként való ábrázolása

A páronkénti nettó előrejelzési hiba variancia dekompozíció (FEVD) — amelyet a kapcsolati mátrix transzponáltjának és a kapcsolati mátrixnak a különbségeként határoznak meg — egy súlyozott, irányított hálózatot definiál. Ennek megfelelően a kapcsolati mátrix átalakítható egy páronkénti nettó kapcsolati hálózattá, ahogyan azt a 6.2. ábra szemlélteti.


Az ábra a napi hozam volatilitás alapján meghatározott kapcsolati hálózatot mutatja be, ahol az irányított élek a volatilitás átterjedésének irányát reprezentálják a biztosítótársaságok között. Az él színe a kapcsolat erősségét jelzi: kék az 1. percentilishez, lila az 5. percentilishez, zöld pedig a 10. percentilishez tartozó hatásoknak felel meg. Az ábrán a 10. percintilisnél gyengébb kapcsolatok nincsenek megjelenítve. A csomópontok mérete arányos a csomóponthoz kapcsolódó élek számával, ami a szereplő hálózaton belüli fontosságát tükrözi.

Ebben a hálózatban a *SCR.PA* (Scor SE) vállalat jól láthatóan a középpontban helyezkedik el, és számos vállalat felé indul belőle irányított él. Ez arra utal, hogy a Scor részvényének volatilitása erősen hozzájárul a piaci sokkok továbbgyűrűzéséhez. Az *ACA.PA*,

valamint BNP.PA vállalatok szintén bekapcsolódnak a volatilitás-átadási láncba kimenő kapcsolatokkal rendelkezve.

A G.MI (Generali) és ALV.DE (Allianz) szintén fontos csomópontként jelennek meg: mindkettő beérkező hatások célpontjaként jelenik meg a hálózatban.

Az élırányok alapján több vállalat, például MUV2.DE vagy CS.PA kiszolgáltató helyzetű befogadóként jelenik meg. Az ábra jól szemlélteti, hogy egyes szereplők hogyan járulnak hozzá a rendszer egészének volatilitásához, míg mások elsősorban reagálnak a külső ingadozásokra.



6.2. ábra. A vállalati kapcsolódás ábrája


6.4. Mozgóablakos alkalmazás – Spillover vs. Connectedness

A fenti módszerek mozgóablakos alkalmazásához csak a mozgó ablak méretét, az ablak elmozdításának mértékét, az MA(q) modell rendjét (q), valamint a VAR/SVAR késleltetések számát kell meghatározni, majd iterálni az adatállományon.

A dolgozatban 100 napos ablakot használtam, 10 nap mértékű elmozdítással, a VAR/SVAR

késleltetés rendje $p = 1$ és a mozgóátlag reprezentáció rendje pedig $q = 10$ paraméterű, ahogy a teljes időszakon illesztett VAR modellé.

6.4.1. Spillover és Connectedness Indexek



6.3. ábra. Spillover (Ortogonalis) és Connectedness (Nem ortogonalis) indexek

A 6.3 ábra mintegy betekintést nyújt a pénzügyi piacok láthatatlan hálójába. Megmutatja, hogy a teljes előrejelzési hiba mekkora része – százalékos formában – a különböző szereplők közötti kölcsönhatások, azaz a kapcsoltság (spillover/connectedness) következménye egy 10 napos előretekintés esetén. Matematikailag ezt úgy tudjuk értelmezni, hogy az adott időpillanathoz tartozó spillover és connectedness mátrixban az összes nem diagonális érték – tehát az egymásra ható tényezők – összegét elosztjuk a mátrix teljes összegével, így feltárva, hogy milyen mértékben származik a volatilitás más szektorokból.


Az ábra alapján látható, hogy a két index dinamikája rendkívül hasonló, ami arra utal, hogy a piaci kapcsoltság mértékét – még eltérő modellezési feltételek mellett is – hasonló mintázatok jellemzik. A *connectedness* index kissé simább, mivel a nem ortogonalis sokkok hatását is tartalmazza, míg a *spillover* index az ortogonalis, függetlenített impulzusokra épül, így érzékenyebb és ingadozóbb lehet különösen a stresszidőszakokban

(pl. a 2021-es év közepén valamint a 2023-as évben). Ez azért van, mert a *spillover* index az ortogonalitás miatt az egyidejű hatásait a sokkoknak nem veszi figyelembe így alacsonyabb kapcsoltságot mutat, mint a *connectedness*. Meglepő módon az indexek annyira szoros kapcsolatban állnak egymással, hogy még akkor is, ha a sokkokat mesterségesen függetlenítjük egymástól, az előrejelzési hiba szinte változatlan marad – mintha a piac szövete olyan sűrű lenne, hogy bármilyen pontját érjük, az egész háló megrezdül.

Fontos megjegyezni, hogy a *spillover* index érzékenyebb és kevésbé stabil, mint a *connectedness* index, és hirtelen, nagyobb negatív irányú kilengéseket tud produkálni. Ez arra utal, hogy ezeknél a mély eséseknél a kapcsoltság jelentős része nem késleltetett, hanem azonnali – azaz az azonos idejű, szimultán hatásokat rögzíti jobban a *connectedness* mutató. Emiatt az ilyen típusú dinamikák csak a nem ortogonális megközelítésben válnak láthatóvá.

6.4.2. Teljes irányított kapcsolódás és volatilitás-átterjedés

A kapcsolódási és spillover táblázatokat a csúszóablakolással időfüggővé tételének segítségével idősorokat tudtam belőlük generálni. Ezek felhasználásával azt is meg lehet vizsgálni, hogy az egyes részvények mennyi volatilitást adtak át vagy kaptak, illetve melyek voltak nettó volatilitásküldők vagy -fogadók az idő folyamán, ahogyan azt a 6.4., 6.5. és 6.6. ábra mutatja. Az indexekhez hasonlóan a piros vonalak a spillover mértékeket, míg a fekete vonalak a *connectedness* mértékét jelzik.




6.4. ábra. Volatilitás átadás

Az 6.4. ábrán jól látható, hogy 2020 márciusában – a COVID-19 járvány globális piaci sokkja idején – a legtöbb részvény esetén hirtelen, jelentős növekedés figyelhető meg, különösen a spillover mutató esetében. Ez arra utal, hogy ezekben az időszakokban a vállalatok aktívan közvetítették volatilitásukat más szektorok felé.

Kiemelendő például a *G.MI*, *CS.PA* és *PST.MI*, amelyek többször is látványos kiugrást mutatnak, különösen 2020 és 2022 kritikus időszakaiban. Ezek a szereplők tehát fontos volatilitási forráspontokként azonosíthatók.

A két index közötti eltérésből azt is leolvashatjuk, hogy az azonnali, nem ortogonális visszacsatolások mikor játszanak nagyobb szerepet. Például a *BNP.PA* és *ACA.PA* esetében a *connectedness* mutató gyakran a *spillover* felett alakul, jelezve, hogy a volatilitás nem csupán késleltetve, hanem szimultán módon is továbbgyűrűzhet.

Ezek az eredmények megerősítik, hogy válságidőszakokban az egyes részvények fokozott szerepet játszhatnak a piaci volatilitás eloszlásában, és az azonnali hatások dominanciája miatt indokolt a connectedness index figyelembevétele is.



6.5. ábra. Volatilitás fogadás

A 6.5 ábra az egyes részvények által fogadott volatilitási sokkok időbeli alakulását szemlélteti.


Az előző ábrához képest itt a fogadott kapcsolatok átlagos szintje valamivel alacsonyabb, és szűkebb tartományban mozognak.

A *connectedness* index szintje sok részvény esetében 75-85 körüli stabil értéken mozog, például a *MUV2.DE*, *MAP.MC* és *CS.PA* esetében. Ezek azt jelzik, hogy a szimultán, nem késleltetett hatások kiemelt szerepet játszanak a volatilitási kapcsolatban. A *spillover* ezzel szemben gyakrabban mutat nagyobb kilengéseket, különösen válságidőszakokban, mint amilyen a 2020 márciusi COVID-19 piaci sokk volt, vagy a 2022-es energiaválság környéke.

Kiemelkedően magas volatilitás-fogadó szerep figyelhető meg a *PST.MI*, *BNP.PA*, *SCR.PA* és *ALV.DE* részvényeknél. Ezek a részvények rendszeresen nagymértékű volatilitást fogadnak be más szereplőktől, ami sebezhetőségre vagy erős piaci beágyazottságra utalhat. A *G.MI* viszont inkább volatilitást kibocsátó, mint fogadó szereplő a hálózatban.

Az ábrák közötti összevetés alapján világosan látható, hogy a volatilitás fogadása kevésbé koncentrált, és kevésbé hektikus mint a továbbadás. Ez azt sugallja, hogy a hálózat stabilitását főként néhány kiemelkedő kibocsátó részvény határozza meg, míg a fogadó

oldal szélesebb körben oszlik el.



6.6. ábra. Nettó volatilitási összekapcsoltság

A 6.6 ábra az egyes részvények nettó volatilitási kapcsolódását mutatja be, amely a volatilitás továbbadásának és fogadásának különbségét tükrözi. A pozitív értékek azt jelzik, hogy az adott részvény inkább kibocsátója a volatilitásnak, míg a negatív értékek arra utalnak, hogy az adott szereplő inkább fogadja a volatilitási sokkoknak. Az ábra alapján látható, hogy néhány részvény – például MAP.MC, SCR.PA, ALV.DE – következetesen pozitív nettó értékeket mutat, vagyis ezek a piaci szereplők a legtöbb időszokban több volatilitást bocsátanak ki, mint amennyit fogadnak. Ez arra utalhat, hogy ezek domináns, vagy „forráspontként” működő szereplők a hálózatban. Ezzel szemben részvények, mint BNP.PA, ACA.PA vagy PST.MI esetében gyakran fordul elő, hogy az értékek tartósan negatív tartományban maradnak, jelezve, hogy ezek inkább passzívan követik a más részvényekből érkező volatilitási hatásokat. A kilengések időben is jól követhetők: a COVID-19 válság (2020 eleje) és az energiaválság/ukrán háború (2022 eleje) során számos részvény esetében tapasztalhatunk hirtelen elmozdulásokat, ami arra utal, hogy a rendszerben átrendeződtek a domináns kibocsátók és a fogadók. Például a *SCR.PA* részvény nettó hatása a 2022-es időszakban meredeken megugrik, tehát ő elkezd jobban terjesztővé válni, míg a *BNP.PA* esetében inkább visszaesés látható, azaz ő elkezd jobban befogadó-

ként viselkedni. A nettó volatilitási kapcsolódás vizsgálata fontos kiegészítése az átadás és fogadás külön-külön történő elemzésének, mivel egyértelműen megmutatja, hogy az egyes biztosítótársaságok a rendszer stabilizáló vagy destabilizáló irányába hatnak-e az adott időszakban.

6.4.3. Mozgóablakos Nettó Kétváltozós Spillover és Connectedness


A connectedness mértékének felhasználásával arra is lehetőség van, hogy két részvényt összehasonlítsunk, és megállapítsuk, hogy melyik volt a nettó küldő vagy fogadó. Az 6.7., 6.8. valamint 6.9. ábrák 2-2 vállalat közötti irányított kapcsolódást mutatja be a connectedness mutató segítségével, 2018 és 2024 között. A függőleges tengelyen a volatilitásátadás mértéke látható, míg a vízszintes tengely az időbeli alakulást szemlélteti. Az ábrákon láthatjuk, hogy az ábrák címeiben szereplő első szereplő milyen mértékben járult hozzá a második szereplőhöz a tíz napos előrejelzési hiba dekompozíciója alapján. (pl. 6.7. ábra esetén SCR.PA-t értem első szereplő alatt, ALV.DE-t második alatt. stb.)



6.7. ábra. Kétváltozós kapcsolódás az SCOR SE (SCR.PA) és az ALLIANZ (ALV.DE) között


Például a 6.7 ábrán láthatjuk, hogy az SCR.PA többségében átadta volatilitását az ALV.DE felé, hiszen az értékek javarészt nulla felett vannak. Láthatjuk az ábrán, hogy 2020-ban a volatilitáskapcsolat megugrott. 2020 elején elkezdett magasabb értékeket felvenni, majd visszaesett. Ez a mintázat tükrözi a világjárvány okozta piaci bizonytalanságot, amely ideiglenesen fokozta a kapcsolódást a biztosítók között. 2021-ben a kapcsolat egyre lejjebb esett. A piaci helyzet viszonylag stabilizálódott, így a volatilitás-átadás is csökkent. 2022 elejétől, az orosz-ukrán háboú kezdetétől a kapcsolódás fokozatosan erősödött. A SCOR SE egyre nagyobb mértékben járult hozzá az Allianz volatilitásához, amely

a geopolitikai feszültségek következtében nőtt. 2022 második felére az érték tartósan 10% fölé emelkedett. A kapcsolat 2023 elején visszaesett 2-3%-ra, majd onnantól kezdve elkezdett fokozatosan erősödni és 2024 végén érte el csúcspontját, elérve majdnem a 30%-ot, ami a vizsgált időszak legerősebb volatilitás-átterjedését jelezte. Ez az időszak erős piaci stresszre vagy bizonytalanságra utal, ahol a SCOR SE jelentősen megnövelte az Allianz részvényének volatilitását.



6.8. ábra. Kétváltozós kapcsolódás az a Generali(G.MI) és a Crédit Agricole S.A. (ACA.PA) között

A 6.8 ábrán azt láthatjuk, hogy javarészt nulla alattiak az értékek, a G.MI 2018 és 2020 között csökkentette az ACA.PA volatilitását, majd 2021 elejétől fokozatosan közeledett nullához és 2022 elejére elérte a nullát, de ezután megint visszaesett és a Generali újfent elkezdte csökkenteni a Crédit Agricole S.A. volatilitását.



6.9. ábra. Kétváltozós kapcsolódás az Allianz (ALV.DE) és a Generali(G.MI) között

Az 6.9 ábrán a G.MI (Assicurazioni Generali) és az ALV.DE (Allianz SE) közötti irányított kapcsolódást láthatjuk. Az ábra alapján elmondhatjuk, hogy a kapcsolat alapvetően gyenge és ingadozó, több periódusban is közel a nullához tart. Ugyanakkor bizonyos időszakokban – különösen 2018 elején és 2023 második felében – erőteljes pozitív vagy negatív értékek jelentkeznek. A 2018-as év elején tapasztalt $+7$ feletti érték azt sugallja, hogy ebben az időszakban a Generali jelentősen befolyásolta az Allianz volatilitását.


A kapcsolat 2020 és 2022 között jellemzően gyenge vagy negatív tartományban mozgott, majd 2023-ban újra erősödés figyelhető meg. Az ezt követő hirtelen csökkenés és mélypont (-7 alatt) 2023 végén és 2024 elején erőteljes szerkezeti átrendeződést vagy külső sokk hatását jelezheti olyan irányba, hogy itt már az Allianz befolyásolja a Generalit.

6.5. A tőke alapján rangsorolt EU-s biztosítótársaságok modellje

Jelen fejezetben a tőke alapján rangsorolt Európai Unió biztosítótársaságokra alkalmazom a bemutatott módszertant. A dolgozatban a következő európai biztosítótársaságok részvényárfolyamait kérdeztem le a Yahoo! Finance adatbázisából (5. fejezet alapján):

- **ALV.DE** – Allianz SE (Németország),
- **CS.PA** – AXA SA (Franciaország),
- **MUV2.DE** – Münchener Rückversicherungs-Gesellschaft AG (Németország),
- **NN.AS** – NN Group N.V. (Hollandia),
- **G.MI** – Assicurazioni Generali S.p.A. (Olaszország),
- **PST.MI** – Poste Italiane S.p.A. (Olaszország),
- **TLX.DE** – Talanx AG (Németország),
- **ACA.PA** – Crédit Agricole S.A. (Franciaország),
- **MAP.MC** – Mapfre S.A. (Spanyolország).

A 6.10 ábrán bemutatott napi volatilitásokat a 6.4 táblázat foglalja össze, amely az évesített volatilitási értékeket tartalmazza:



6.10. ábra. Tőke alapú rangsorolás: logaritmikus volatilitás

6.4. táblázat. Tőke alapú részvények évesített volatilitásának statisztikai jellemzői

Részvény	Megfigyelések	Átlag	Medián	Szórás	Minimum	Maximum
G.MI	1769	0,1586749	0,1247415	0,1379000	0	1,558677
CS.PA	1769	0,1758885	0,1357214	0,1610263	0	1,850402
MUV2.DE	1769	0,1665224	0,1287116	0,1524866	0	1,548215
MAP.MC	1769	0,1856736	0,1486146	0,1598914	0	1,555984
TLX.DE	1769	0,1724680	0,1340728	0,1580428	0	1,581563
PST.MI	1769	0,1878200	0,1469159	0,1690301	0	1,679769
ACA.PA	1769	0,2165774	0,1700404	0,1913325	0	1,774412
ALV.DE	1769	0,1535432	0,1147702	0,1450909	0	1,599191
NN.AS	1769	0,1801255	0,1374914	0,1666331	0	1,554691

A 6.4 táblázat a tőkealapú kiválasztás alapján összeállított részvényportfólió évesített volatilitásának statisztikai jellemzőit mutatja be. A bemutatott adatok összevethetők a korábbi 6.1 bruttó díjbevétel alapján készült táblázattal. A két mintában a különbségek: a tőkealapú kiválasztás esetében az NN.AS részvény került be újként, míg a BNP.PA és SCR.PA részvények kimaradtak.

Az összehasonlítás alapján elmondható, hogy a főbb statisztikai mutatók (átlag, medián, szórás) nagyságrendje a két minta között nem tér el jelentősen. A legmagasabb átlagos volatilitással továbbra is az ACA.PA és PST.MI részvények rendelkeznek, míg az ALV.DE részvény mindkét mintában a legalacsonyabb volatilitási értékeket mutatja. Az NN.AS átlagos volatilitása (0,1801) a mezőny középső harmadába esik, így jól illeszkedik az eddig vizsgált részvények profiljába.

A szórás és a szélsőértékek alapján a tőkealapú minta is kellően változatos képet mutat: a maximális évesített volatilitás értékei több részvélynél meghaladják az 1,5-ös szintet, akárcsak a bruttó díjbevétel alapján készült mintában.

Bár a tőkealapú portfólió részvényei némileg eltérnek a bruttó díjbevétel alapján készült mintától, a volatilitási jellemzők megőrzik a korábbi szerkezetet.

Volatilitási spillover mátrix értelmezése és elemzése

A 6.5 tábla a spillover tábla a tőke alapján rangosorolt biztosítók idősoraira. Ez a következőképpen néz ki:

6.5. táblázat. Tőke: Volatility Spillovers

	G.MI	CS.PA	MUV2.DE	MAP.MC	TLX.DE	PST.MI	ACA.PA	ALV.DE	NN.AS	From
G.MI	71	6	2	9	1	6	5	1	0	29
CS.PA	3	71	3	9	1	6	8	0	0	29
MUV2.DE	2	5	72	10	0	4	5	0	0	28
MAP.MC	1	6	2	75	1	5	8	1	0	25
TLX.DE	3	6	2	9	68	5	6	1	0	32
PST.MI	0	12	3	9	1	69	6	0	0	31
ACA.PA	1	7	3	13	1	7	68	1	0	32
ALV.DE	2	4	3	8	1	5	6	72	0	28
NN.AS	2	7	2	9	1	5	8	2	65	35
To	13	54	20	75	6	43	52	6	1	30

A 6.2 és 6.5 táblázatok a volatilitás áttérjedésének szerkezetét mutatják be két eltérő részvénykiválasztási szempont alapján. A 6.2 táblázat vállalatai bruttó díjbevétel szerint lettek rangsorolva, míg a 6.5 táblázat a piaci kapitalizáció (tőkeérték) alapján összeállított portfóliót tartalmazza. A két szemlélet eredményeként különböző vállalatok kerülnek be a mintába, így a kapcsoltsági mintázatok is különböző képet mutatnak.

A „To” értékek, vagyis az egyes részvények által másokra továbbadott volatilitás tekintetében a 6.5. táblázatban szintén kiemelkedő szerepet játszik az MAP.MC és CS.PA, ahogyan az a korábbi bruttó díjbevétel alapján készült táblában (6.2. is jelen volt. Ugyanakkor a tőkealapú mintában a ACA.PA is előtérbe kerül 52-es értékkel, amely a bruttó díjbevétel-alapú mintában még nem tartozott a legnagyobb volatilitáskibocsátók közé. Emellett a SCR.PA, amely a bruttó díjbevétel-alapú mintában az egyik legmagasabb „To” értéket mutatta (48), teljesen hiányzik a tőkealapú mintából, így az általa közvetített kapcsolatok más részvények között oszlanak el.

A „From” értékek, tehát a fogadott volatilitás szerint a bruttó díjbevétel-alapú mintában a legnagyobb mértékű beáramlás a BNP.PA (45) és ACA.PA (36) részvényeket érte. A tőkealapú mintában az újonnan megjelenő NN.AS (35) részvény vált a legérzékenyebbé a külső sokkokra. Emellett az ACA.PA (32) ebben a mintában is érzékeny a külső sokkokra, valamint a TLX.DE (32) is.

Ezzel szemben néhány részvény, mint például a CS.PA, ALV.DE vagy MUV2.DE mindkét mintában stabil, kiegyensúlyozott kapcsoltsági profilt mutat, ami arra utal, hogy ezen vállalatok volatilitásbeli viselkedése kevésbé függ a kiválasztási kritériumtól.

A vizsgált rendszerben a részvények volatilitásának átlagosan 30%-a más részvények sokkjaira vezethető vissza. A bruttó díjbevétel alapján kialakított mintában ez az arány 32% volt, ami enyhén magasabb szintű volatilitás-átterjedésre utal.

Elmondhatjuk tehát, hogy a piaci kapcsolatok feltárása jelentősen függ attól, hogy

milyen gazdasági jellemzők mentén történik a vállalatok kiválasztása.

Volatilitási kapcsolódási mátrix értelmezése és elemzése

A 6.6 mátrix a biztosítótársaságok közötti volatilitási kapcsolatok erősségét mutatja, a Diebold–Yilmaz (2012) módszertana alapján. Az egyes mátrixelemek azt fejezik ki, hogy egy adott vállalat (sor) mekkora mértékben járul hozzá egy másik vállalat (oszlop) volatilitásához. A diagonális elemek a saját magyarázott volatilitást jelölik, míg a *To* és *From* sorok segítségével meghatározható az egyes szereplők *nettó volatilitási hatása* a rendszerre.

6.6. táblázat. Tőke: Volatility Connectedness

	G.MI	CS.PA	MUV2.DE	MAP.MC	TLX.DE	PST.MI	ACA.PA	ALV.DE	NN.AS	From
G.MI	11.72	11.02	9.83	10.85	9.35	13.12	16.42	8.54	9.15	88.28
CS.PA	8.29	14.61	10.24	10.42	9.73	11.27	16.77	9.07	9.59	85.39
MUV2.DE	7.85	11.15	14.85	11.03	10.88	10.85	14.92	9.39	9.08	85.15
MAP.MC	7.96	10.51	9.85	17.06	9.39	11.16	17.07	8.16	8.84	82.94
TLX.DE	7.71	10.84	11.37	10.79	14.81	11.08	15.16	9.08	9.16	85.19
PST.MI	9.00	9.84	9.43	10.24	8.85	18.29	16.52	8.18	9.65	81.71
ACA.PA	8.09	10.81	9.03	10.96	8.64	11.79	23.24	8.14	9.30	76.76
ALV.DE	8.06	11.61	10.96	10.61	9.86	11.32	16.16	11.81	9.60	88.19
NN.AS	7.39	10.24	9.30	10.50	9.26	11.35	16.52	8.20	17.24	82.76
To	64.34	86.03	80.02	85.40	75.97	91.94	129.55	68.76	74.35	84.04


A tőkealapú rangsorolás alapján készült 6.6. (Volatility Connectedness) táblázat eredményei több szempontból is eltéréseket mutatnak a bruttó díjbevétel alapú rangsorolás szerint számított eredményekhez képest.

A "From" értékek általánosságban véve alacsonyabbak a tőkealapú mintában, mint a bruttó díjbevétel alapúban. Ez arra utal, hogy a tőkeerősebb biztosítótársaságok kevésbé függenek más szereplők volatilitásának átvételétől, vagyis saját piaci mozgásuk nagyobb önállóságot mutat. Például a G.MI, CS.PA, MUV2.DE és ALV.DE társaságok esetében a "From" értékek kisebb csökkenést jeleznek, ugyanakkor más vállalatoknál is hasonló tendencia figyelhető meg.

A "To" értékek, vagyis a más szereplőkre gyakorolt volatilitási hatás mértéke általánosságban magasabb a tőkealapú mintában. Különösen kiemelkedik az ACA.PA (Crédit Agricole) és a PST.MI (Poste Italiane) szerepe, amelyek a tőkealapú rangsorban lényegesen nagyobb hatást gyakoroltak a rendszer egészére, mint a bruttó díjbevétel alapú rangsorolás esetében. Az ACA.PA "To" értéke 129,55-re emelkedett az előző 118,46-höz képest, míg a PST.MI esetében 91,94-ről beszélhetünk a korábbi 80,94 helyett.

Az eredmények arra utalnak, hogy a tőkeerősebb biztosítótársaságok nemcsak stabilabbak a külső volatilitás-sokkokkal szemben, hanem aktívabb szerepet is játszanak a volatilitás továbbadásában a piac más szereplői felé. Összességében a tőkealapú mintában a rendszer kapcsolódási intenzitása is magasabbnak bizonyult, amit az átlagosan magasabb "To" értékek is alátámasztanak. Érdekes megemlíteni, hogy a teljes kapcsoltsági index értéke a tőkealapú mintában 85,37-ről lecsökkent 84,04-re, ami mérsékelt csökkenést jelent a rendszer összekapcsoltságának szintjében. Ez a változás nem utal radikális szerkezeti átrendeződésre, mindössze kisebb elmozdulásokat eredményezett az egyes szereplők pozíciójában a díjbevétel-alapú rangsorhoz képest. Csak egy átrendeződés tapasztalható az ACA.PA felé, mint fő volatilitás-továbbító.

6.5.1. Tőke alapú rangsorolás: Teljes mintás FEVD hálózatként való ábrázolás




6.11. ábra. Tőke alapú rangsorolás: vállalati kapcsolódás ábrája

A 6.11 ábra a tőke alapján rangsorolt biztosítótársaságok közötti kapcsolatokat jeleníti meg a napi hozamok volatilitása alapján. Hasonlóan, mint a bruttó díjbevétel alapú minta esetén az él színe a kapcsolat erősségét jelzi: kék az 1. percentiliséhez, lila az 5.

A kapcsolati irányok alapján megfigyelhető, hogy több vállalat – például MUV2.DE, MAP.MC vagy TLX.DE – fogadóként viselkedik, hiszen az ACA.PA felől feljük indulnak élek. Ez arra utal, hogy ezen szereplők részvényeinek ingadozására hatást gyakorol az ACA.PA részvényeinek volatilitása. Más vállalatok, mint például ALV.DE vagy NN.AS is inkább befogadóként jelennek meg a hálózatban, mivel bejövő élekkel rendelkeznek.

6.5.2. Tőke alapú rangsorolás: Spillover és Kapcsolódási indexek




6.12. ábra. Tőke: Spillover (Ortogonalis) és Kapcsolódási (Nem ortogonalis) indexek

Az 6.12 ábrán jól látható ezen idősorok alapján is, hogy a két index alakulása nagyfokú hasonlóságot mutat, és az értékeik erősen együtt mozognak. Jelen esetben is ez arra utal, hogy a rendszer viselkedése szempontjából nincs jelentős különbség aközött, hogy ortogonális (korrelálatlan) vagy generalizált (korrelált) sokkokat alkalmazunk. A connec-

tedness és spillover indexek tehát ebben az esetben is hasonló képet festenek a volatilitás hálózati szerkezetéről és annak időbeli változásairól. Az is látható, hogy a tendenciák hasonlóak, mint a díjbevételes vizsgálatnál. Például itt is jelen van a 2023-as visszaesés az összekapcsoltságban. Fontos itt is kiemelni, amit már a 6.3 ábrán is megjegyeztem. A Spillover index érzékenyebb és kevésbé stabil, mint a Connectedness index. A Spillover index mutató nagyobb irányváltásokat jelezhet, amelyek nem feltétlenül tükrözik valós piaci kapcsolatokat, hanem inkább a módszertanból fakadó technikai hatások következményei lehetnek.

6.5.3. Tőke alapú rangsorolás: teljes irányított kapcsolódás és volatilitás-átterjedés

A kapcsolódási és spillover táblázatok idősortartalmának felhasználásával a tőke alapú rangsorolásban is meg tudjuk vizsgálni, hogy az egyes részvények mennyi volatilitást adtak át vagy kaptak, illetve melyek voltak nettó volatilitásküldők vagy -fogadók az idő folyamán, ahogyan azt a 6.13., 6.14. és 6.15. ábra mutatja. Az indexekhez hasonlóan a piros vonalak a spillover mértékeket, míg a fekete vonalak a connectedness mértékét jelzik.




6.13. ábra. Tőke: Volatilitás átadás

A 6.13 ábrán szereplő vállalatok közül többenél jelentős kilengések figyelhetők meg, hasonlóan, mint a bruttó díjbevételeknél készült ábra esetén. A tőke alapján készült minta esetében a volatilitás átadási értékek – különösen a *spillover* index esetén – jellemzően

magas szórást és heves kiugrásokat mutatnak, különösen a 2020-as és 2022-es időszakokban. Például a *G.MI*, *CS.PA* és *MUV2.DE* esetében a piros vonal hirtelen 300 fölé is emelkedik.

A két mutató eltérései itt is megfigyelhetők: a *connectedness* index (fekete vonal) gyakran stabilabb és kevésbé volatilis, míg a *spillover* index (piros) gyorsan reagál az új sokkokra és kilengésekre. Ez az eltérés különösen erős például a *MAP.MC* és *PST.MI* esetében, ahol időnként magas eltérés figyelhető meg a két görbe között.



6.14. ábra. Tőke: Volatilitás fogadás


Általánosságban megállapítható, hogy a fogadási oldal értékei alacsonyabbak és kevésbé hektikusak, mint az átadás esetén. A *connectedness* görbék jellemzően stabilan 70–80% között mozognak, míg a *spillover* indexek szélesebb intervallumban, körülbelül 25 és 75 között ingadoznak, de csak ritkán lépik túl ezt a tartományt. Ez a jelenség például a *CS.PA*, *MAP.MC* vagy *ACA.PA* esetében is megfigyelhető.

A 2020-as COVID-válság és a 2022-es inflációs sokk időszakaiban a legtöbb vállalatnál emelkedés látható, ugyanakkor ezek az emelkedések sokkal mérsékeltőbbek, mint az átadás ábrán tapasztalt kiugrások. Ez arra utalhat, hogy a tőke alapján készült mintának egyes vállalatai inkább volatilitást bocsátanak ki, mintsem hogy másoktól fogadnának.

A fogadási oldalon különösen érdekes a *PST.MI*, *ALV.DE* és *NN.AS* viselkedése, ahol a *spillover* indexek időszakosan erőteljesebb ingadozást mutatnak. Ennek oka lehet, hogy ezek a vállalatok érzékenyebbek bizonyos külső sokkokra, vagy periférikusabb pozícióban

helyezkednek el a rendszerben.

A tőke alapú mintában a volatilitás főként néhány szereplőtől indul ki, és csak kisebb mértékben oszlik szét a fogadó vállalatok között.



6.15. ábra. Tőke: Nettó volatilitási összekapcsoltság

A két megközelítés közötti legjelentősebb különbség a kapcsolatok intenzitásában és stabilitásában figyelhető meg. A tőke alapján csoportosított vállalatok ábráján a *connectedness* értékek gyakran meghaladják a 200-as szintet is, különösen 2020-ban és 2022-ben, ami arra utal, hogy ezek a vállalatok hangsúlyosabb szerepet töltenek be a rendszer volatilitásának strukturálásában.

Ezzel szemben a bruttó díjbevétel szerint rendezett nettó volatilitási összekapcsoltsági ábrákon a nettó kapcsolatok jellemzően szűkebb sávban mozognak, többnyire -100 és +150 között. Ez azt jelzi, hogy bár ezek a vállalatok jelentős üzleti volumenűek, nem feltétlenül ők dominálják a rendszer dinamikus sokkterjedését.


További különbség, hogy a bruttó díjbevétel alapján csoportosított esetben az értékek gyakrabban közelítik meg a nullát, azaz a vállalatok szerepe gyakrabban vált át adóból fogadóba és fordítva. Ezzel szemben a tőke szerint csoportosított elemzés több stabilan „adó” pozícióban lévő vállalatot mutat, ami az erőteljesebb és állandóbb piacbefolyásra utal. Ilyen például *MAP.MC* vagy *G.MI* valamint *ACA.PA*, ami a teljes időszakon vett hálózaton is fő továbbító. Úgy látszik, hogy a legtöbb időpontban ez a szerepe stabil a *connectedness* szerint, csak a *spilloverben* hektikusabb. Tehát a nettó továbbító szerepéhez,

amit a teljes időszaki hálózatban láttunk kellene az egyidejű sokkhatások.

A két ábra összevetése rámutat arra, hogy a volatilitás áramlása a biztosítói hálózaton belül nem egyenletes: néhány szereplő aktív forrásként, míg mások passzív befogadóként vannak jelen, ami fontos információ a rendszerkockázat eloszlásának és szerkezetének megértéséhez.

6.5.4. Tőke alapú rangsolorlás: Mozgóablakos Nettó Kétváltozós Spillover és Kapcsolódás

A kapcsolódás mértékének felhasználásával lehetőségünk van jelen minta esetén is arra, hogy két részvényt összehasonlítsunk, és lássuk, melyik volt a nettó küldő vagy fogadó.



6.16. ábra. Kétváltozós kapcsolódás az Allianz (ALV.DE) és az NN(NN.AS) között

A 6.16 ábra az ALV.DE (Allianz SE) és NN.AS (NN Group) közötti irányított kapcsolódás időbeli alakulását mutatja be a connectedness mutató segítségével 2018 és 2024 között.

Az ábrán látható, hogy a kapcsolat értéke időben változó és mind pozitív, mind negatív tartományban mozgott. A nulla körüli értékek alapján elmondhatjuk, hogy az adott időszakban az Allianz hatása elhanyagolható volt. A negatív értékek arra utalnak, hogy a kapcsolat erőssége csökkent, vagy akár inverz irányú volt (azaz a modell alapján nem Allianz magyarázta a NN Group volatilitását, hanem az NN küldött volatilitást az Allianznak). A pozitív értékek ezzel szemben azt jelentik, hogy az Allianz jelentősebb hatást gyakorolt a NN Group részvényének volatilitására.

Különösen szembetűnő a 2022, valamint 2023 első felében megfigyelhető hirtelen zuhanás, amikor az irányított kapcsolódás értéke -15 alá esett. Ez egy esetleges strukturális törés vagy egy erőteljes piaci sokk következménye lehet, amely átmenetileg teljesen meg-

változtatta az Allianz és a NN Group közötti volatilitás-összefüggést. A 2023 eleji zuhanást követően azonban erőteljes növekedés figyelhető meg, 2024 elejére a nullát is átlépve.

Kijelenthetjük az eredmények alapján, hogy az $ALV.DE \rightarrow NN.AS$ kapcsolat dinamikusan változó, időszakonként erősödő és gyengülő hatásokkal, amely jól tükrözi a pénzügyi piacok időben változó szerkezetét.



6.17. ábra. Kétváltozós kapcsolódás az AXA (CS.PA) és az Allianz (ALV.DE) között

A 6.17. ábra alapján elmondhatjuk, az időszak nagy részében az AXA irányából az Allianz felé irányuló volatilitási hatások mérsékeltek, jellemzően 2 és 5 közötti connectedness értékekkel.

Ugyanakkor a kapcsolat 2022 közepétől látványosan megerősödik, 2023 második felében pedig 10 fölé is emelkedik, ami fokozott volatilitásátzivargást jelez AXA irányából. Ez az időszak a pénzügyi piacok bizonytalanabb fázisával (pl. kamatemelési ciklus, makrogazdasági kockázatok) is egybeeshet.

Az erősödő kapcsolatot követően 2024 elejére az értékek visszaesnek, ami arra utal, hogy az átmeneti sokkhatások enyhültek, és a piac struktúrája ismét nyugodtabb állapotba került. A kapcsolat nem állandó, inkább ciklikus jellegű. Ez az ábra is jól illusztrálja, hogy a volatilitási terjedés folyamatosan változó, nemlineáris módon reagál a piaci eseményekre.

7. fejezet

Összefoglalás

A dolgozatban az európai biztosítótársaságok részvényei közötti volatilitás-átterjedési mintákat vizsgáltam a 2018 és 2024 közötti időszakban. A részvényárfolyamok napi adataira építve elemeztem, hogy a piaci sokkok – különösen a COVID-19 világjárvány és az orosz–ukrán háború – miként alakították át a szektor szereplői közötti kapcsolódási szerkezetet. A vizsgálat során vektor-autoregresszív (VAR) modelleket és a Diebold–Yilmaz-féle kapcsolódási keretrendszert alkalmaztam, amely lehetővé tette a volatilitás-hatások irányított és kvantitatív elemzését az egyes piaci szereplők között.

A kutatás során nemcsak a teljes mintás összefüggéseket elemeztem, hanem mozgóablakos megközelítést is alkalmaztam annak érdekében, hogy feltárjam a volatilitás-terjedés időbeli dinamikáját. Összességében a spillover és connectedness indexek alapján nem láthatjuk, hogy a piaci stressz időszakában – különösen a COVID-19 első hulláma és az orosz–ukrán konfliktus kitörésekor – a biztosítók közötti kapcsolatok formálódtak. Érdekes megfigyelés ugyanakkor a 2023 eleji visszaesés a két indexeknél. A dolgozatban bemutattam a teljes kapcsolódási indexeket, az irányított és nettó spillover mutatókat, valamint a páronkénti volatilitás-terjedések időbeli alakulását, vizuális ábrák és hálózati grafikonok segítségével.

Rámutattam arra, hogy bizonyos szereplők – például a Mapfre S.A. és az AXA S.A. – mindkét mintában a legnagyobb volatilitás-kibocsátónak mutatkoztak, valamint a SCOR SE a bruttó díjbevétel alapú mintában emelkedett ki, a Crédit Agricole S.A. pedig a tőke alapú kiválasztásban. Azok közül, akik a legérzékenyebbek voltak a volatilitásra, mindkét mintában kiemelkedő volt a Talanx AG és a Crédit Agricole S.A. A bruttó díjbevétel alapú minta esetén a BNP Paribas S.A. reagált a legérzékenyebben, a tőke alapú minta esetén pedig az NN Group N.V., valamint a SCOR SE. Ezek alapján tehát elmondható, hogy a Crédit Agricole S.A. és a SCOR SE nemcsak nagy hatással vannak más szereplők volatilitására, hanem ők maguk is érzékenyen reagálnak mások volatilitására. Érdeemes megemlíteni, hogy míg a SCOR SE tisztán viszontbiztosítóként működik, addig

a Cr dit Agricole S.A. nem az. A t bbi f  volatilit sterjeszt  k z tt is találunk olyan szerepl ket, amelyek r szben viszontbiztosít k, illetve olyanokat, amelyek nem. Ez rt nem lehet egy rtelm  következtet seket levonni arra n zve, hogy a piaci zavarokat el sz r a k zvetlen biztosít k vagy a m g tt k áll  viszontbiztosít k  r kelik-e, illetve hogy a befektet i aggodalmak mikor jelentkeznek: m r egy viszontbiztosít  megrend lésekor, vagy csak k s bb. A f  terjeszt k k z l az AXA S.A. mind a brutt  d jbev tel, mind a t kealap  rangsorol s szerint az  lmez nyben szerepel, ellent tben a t bbi f  terjeszt vel, akik mindk t rangsorban a mez ny m sodik fel ben helyezkednek el. Ez rt e szempontb l sem figyelhet  meg egys ges mint zat.

E viselked smint k elemz se hozz j rul a p nz gyi stabilit si kock zatok m lyebb meg rt s hez,  s alapul szolgálhat a j v beli v ls gkezel si strat gi k kialakítás hoz. A kutat s eredm nyek nt  tfog  k pet adtam arról, hogyan form l dtak a kock zati kapcsolatok az eur pai biztosít si szektoron bel l a k l nb z  gazdas gi k rnyezetek hatás ra.

Irodalomjegyzék

Achmea (2025) Shareholders.

Elérhető: <https://www.achmea.nl/en/organisation/shareholders> (Letöltve: 2025.04.15.)

Aéma Groupe (2024) Financial Results 2023.

Elérhető: https://www.aemagroupe.fr/wp-content/uploads/2024/04/ENG-CP-Aema-Groupe_Resultats-financiers-2023.pdf (Letöltve: 2025.04.15.)

Antonakakis N., Chatziantoniou I., Gabauer D. (2020) Refined measures of dynamic connectedness based on time-varying parameter vector autoregressions. *Journal of Risk and Financial Management*, 13(4), 84;

<https://doi.org/10.3390/jrfm13040084>

Antonakakis, N., Cunado, J., Filis, G., Gabauer, D., De Gracia, F.P. (2023) Dynamic connectedness among the implied volatilities of oil prices and financial assets: new evidence of the COVID-19 pandemic. *International Review of Economics and Finance*, 83, 114–123;

<https://doi.org/10.1016/j.ieref.2022.10.032>

Banyár, J. (2016) Életbiztosítás, 2. javított, bővített kiadás. Budapesti Corvinus Egyetem.

Elérhető: https://www.researchgate.net/publication/312040373_Eletbiztositas_2_javitott_bovitett_kiadas_2016 (Letöltve: 2025.04.10.)

CNP Assurances (2025) Shareholder.

Elérhető: <https://www.cnp.fr/en/the-cnp-assurances-group/who-we-are/the-governance/shareholder> (Letöltve: 2025.04.15.)

Covéa (2025) Organisation.

Elérhető: <https://www.covea.com/en/organisation> (Letöltve: 2025.04.15.)

Diebold F.X., Yilmaz K. (2009) Measuring Financial Asset Return and Volatility Spillovers, With Application to Global Equity Markets. *Economic Journal*, 119: 158–171;

<https://doi.org/10.1111/j.1468-0297.2008.02208.x>

- Diebold F.X., Yilmaz K. (2012) Predictive directional measurement of volatility spillovers. *International Journal of Forecasting*, 28(1):57-66;
<https://doi.org/10.1016/j.ijforecast.2011.02.006>
- Elyasiani, E., Kalotychou, E., Staikouras, S.K., and Zhao, T. (2015). Return and Volatility Spillover among Banks and Insurers: Evidence from Pre-Crisis and Crisis Periods. *Journal of Financial Services Research*, 48(1), pp. 21–52;
<https://doi.org/10.1007/s10693-014-0200-z>
- Epskamp, S., Waldorp, L. J., Mottus, R., & Borsboom, D. (2018). The Gaussian graphical model in cross-sectional and time-series data. *Multivariate Behavioral Research*, 53(4), 453–480. <https://doi.org/10.1080/00273171.2018.1454823>
- Groupama Assurances Mutuelles (2025) The Group Organisation.
 Elérhető: <https://www.groupama.com/en/our-governance/the-group-organisation> (Letöltve: 2025.04.15.)
- Groupe des Assurances du Crédit Mutuel (2024) Information Memorandum.
 Elérhető: <https://www.acm.fr/fr/document/investisseurs/2024/GACM-Senior-2024-Information-Memorandum-Final.pdf> (Letöltve: 2025.04.15.)
- Haslbeck J.M.B., Bringmann L.F., Waldorp L.J. (2021) A tutorial on estimating time-varying vector autoregressive models. *Multivariate Behavioral Research*, 56(1):120-149;
<https://doi.org/10.1080/00273171.2020.1743630>
- Huszár Z.R., Kotró B.B., Tan R.S.K. (2023) Dynamic volatility transfer in the European oil and gas industry. *Energy Economics*, 127, 107052;
<https://doi.org/10.1016/j.eneco.2023.107052>
- Ghosh, B., Pham, L., Teplova, T., Umar, Z. (2023) COVID-19 and the quantile connectedness between energy and metal markets. *Energy Economics*, 117;
<https://doi.org/10.1016/j.eneco.2023.106752>
- Koop G., Pesaran M.H., Potter S.M. (1996) Impulse response analysis in nonlinear multivariate models. *Journal of Econometrics*, 74(1), pp. 119-147;
[https://doi.org/10.1016/0304-4076\(95\)01753-4](https://doi.org/10.1016/0304-4076(95)01753-4)
- Mohr F.X., (2020) An Introduction to Impulse Response Analysis of VAR Models.
 Elérhető: <https://www.r-econometrics.com/timeseries/irf/> (Letöltve: 2025.01.15.)

- Mroua M., Lamine A.(2024) Do commodities offer diversification benefits during the COVID-19 pandemic crisis? Evidence from dynamic spillover approach. *Heliyon*, 10, e32738;
<https://doi.org/10.1016/j.heliyon.2024.e32738>
- Parkinson, M. (1980). The Extreme Value Method for Estimating the Variance of the Rate of Return. *The Journal of Business*, 53(1), pp. 61-65;
<https://doi.org/10.1086/296071>
- Pesaran H.H., Shin Y. (1998) Generalized impulse response analysis in linear multivariate models. *Economics Letters*, 58(1), pp. 17-29;
[https://doi.org/10.1016/S0165-1765\(97\)00214-0](https://doi.org/10.1016/S0165-1765(97)00214-0)
- Reinsurance News (2024) Largest 30 European insurers ranked by total assets. *Reinsurance News*;
 Elérhető: <https://www.reinsurancene.ws/largest-30-european-insurers/>
 (Letöltve: 2025.04.04.)
- R+V Versicherung AG (2023) Annual Report 2022.
 Elérhető: <https://www.rv-re.com/dam/jcr%3A36ff54d6-f3d1-4242-9118-2b258fbf7a07/Annual%20report%202022.pdf> (Letöltve: 2025.04.15.)
- Sayed, R. (2020) Spillovers and Connectedness. *RPubs*.
<https://rpubs.com/rsayed/573439> (Letöltve: 2025.04.16.)
- Zivot, E. (2016) VAR Models. University of Washington Lecture Notes, ECON 584; Elérhető: <https://faculty.washington.edu/ezivot/econ584/notes/varModels.pdf>
 (Letöltve: 2025.02.03.)

MI-eszközhasználati nyilatkozat

Alulírott, Horváth Adél Roxána, nyilatkozom, hogy szakdolgozatom elkészítése során az alább felsorolt feladatok elvégzésére a megadott MI-alapú eszközöket alkalmaztam:

Feladat	Felhasznált eszköz	Felhasználás helye	Megjegyzés
Nyelvhelyesség ellenőrzése, $\text{\LaTeX}$ kód írása	ChatGPT	Teljes dolgozat	Helyesírási javítások, valamint táblázatok és képletek formázása $\text{\LaTeX}$ -ben.

A felsoroltakon túl más MI-alapú eszközt nem használtam.