

PÉCSI TUDOMÁNYEGYETEM
KÖZGAZDASÁGTUDOMÁNYI KAR

GAZDÁLKODÁSTANI DOKTORI ISKOLA

Uzsoki Máté

A piaci kockázat mérése neurális hálózattal és
statisztikai modellekkel

DOKTORI ÉRTEKEZÉS

Témavezető: Dr. Bugár Gyöngyi, PhD, habil

Pécs, 2021

1 Tartalomjegyzék

1	Absztrakt.....	1
2	A témaválasztás indoklása és a kutatás jelentősége	2
3	Az értekezés felépítése	5
4	Az értekezés hipotézisei	8
5	Az értekezés eredményei.....	9
6	A kutatás továbbfejlesztésének lehetőségei.....	11
7	A téziszűzetben felhasznált irodalom	11

1 Absztrakt

Jelölt: *Uzsoki Máté*

Témavezető: *Dr. Bugár Gyöngyi, PhD, habil.*

Az értekezés célja egyrészt egy olyan átfogó empirikus elemzés elvégzése és bemutatása, ami nagy adathalmazon hasonlítja össze a várható többletveszteség több, mint 50 becslési modelljének teljesítményét. A szakirodalomban számos becslési technika megtalálható, de eddig hiányzott ezek egységes keretrendszerben történő széles körű összehasonlítása. Az empirikus elemzés elvégzéséhez a modelleket 100 S&P500 indexben résztvevő részvény 30 éves idősorán számítom ki. A várható többletveszteség visszatesztelhetőségével, így a modellrangsorolási probléma feloldásával az ilyen jellegű összehasonlítás elvégzése aktuálissá vált. Az értekezésben bemutatott modell összehasonlítás során olyan visszatesztelési eljárást alkalmazok, ami nem igényli a kockázati mérőszám elicítálhatóságát és lehetővé teszi az eredmények összevonását, így a modellek rangsorolását is. Az értekezés eredményei között bemutatom, hogy a klasszikus valószínűségi-eloszlások használatánál lényegesen jobb eredmény érhető el más, kevésbé ismert eloszlások alkalmazásával. Az értekezés második, hasonlóan fontos célja annak vizsgálata, hogy adaptálhatók-e előjelzési modellként az egyre több területen sikeresen alkalmazott neurális hálózatok a várható többletveszteség becslésére. Ennek vizsgálatához egy új megközelítést dolgozok ki, és ez alapján konstruálok egy neurális hálózatot. Az így létrejött és az értekezésben bemutatott többszintű neurális háló a kiválasztott statisztikai modell eredményét tovább javítva, az összes, több mint 50 vizsgált modellnél pontosabban, azaz szignifikánsan kisebb hibával jelzi előre a várható többletveszteséget.

Kulcsszavak: Kockázati modellek, várható többletveszteség, neurális hálózatok, pénzügyi modellezés

2 A témaválasztás indoklása és a kutatás jelentősége

A megfelelő pénzügyi kockázatkezelés jelentőségét számos pénzügyi katasztrófa mellett a 2007-es pénzügyi válság is bizonyítja. A kockázatkezelés egyrészt szabályozói szempontból fontos. A kockázatkezeléssel a szabályozó célja, hogy a pénzügyi szektor ellenálló legyen a különböző sokkhatásokkal szemben, a szereplők kellő mértékű sokkelnyelő képességgel bírjanak ahhoz, hogy akár nagyobb vállalatok bukása esetén se sérüljön a pénzügyi piac olyan mértékben, hogy az a teljes gazdaság teljesítményét kritikus mértékben visszavesse (McNeil, et al., 2015). A 2007-es válság megmutatta, hogy a pénzügyi szereplők hibás kockázatmérése és a kockázatkezelés nem megfelelő mértéke a teljes gazdaság működését visszafoghatja, ezzel súlyos károkat okozva a társadalom számos szereplőjének. Egyértelmű, hogy a pénzügyi területen megjelenő új szabályozások – mint például a Bázeli III. keretrendszer – fontos célkitűzése, hogy választ adjanak a 2007-es válság tanulságaira, így megelőzhetőek a 2007-es válsághoz hasonló krízisek kialakulását a jövőben.

A kockázatkezelés központi eleme a kockázat megfelelő mérése. Ez alapvetően két részből áll: a megfelelő kockázati mérőszám kiválasztásából, valamint a mérőszám megfelelő becslési eljárásának, azaz modelljének kidolgozásából. Kockázati mérőszámként a várható többletveszteség (expected shortfall) mutató használata preferált a szakirodalom alapján. A várható többletveszteség legfőbb előnye, hogy a gazdasági szereplők számára jól értelmezhetően adja meg a kockázat mértékét ellentétben a szórással vagy az expectilisek használatával. A kockázati mérőszám másik előnye, hogy koherens kockázati mutató (Artzner, et al., 1999), ami azt biztosítja, hogy megfelel azoknak az elvárható kritériumoknak, amelyek azt biztosítják, hogy nem lesznek olyan esetek, amikor a mutató bizonyos kockázati faktorokat nem vesz figyelembe. A koherencia tulajdonságával a várható többletveszteség maga mögé utasítja a korábban iparági standardként elterjedt kockázatot érték mutatót (value at risk, VaR). A VaR szintén jól értelmezhetően adta meg a kockázat mértékét, de a koherencia hiánya miatt előfordulhatott olyan eset, amikor két különálló pozíció kockázatának összege kisebb volt, mint az összevont pozíció kockázata. Ez az eset alapvetően mond ellent a kockázatméréssel kapcsolatos intuitív elvárásainknak, és arra a tényre vezethető vissza, hogy a VaR mutató szempontjából „vakfolt” az eloszlás legnagyobb veszteséggel járó széle. Ezekből a hiányosságokból következik a Bázeli III. keretrendszer által előírt

mérőszám váltás, ahol a kockázatot érték mutató helyét a várható többletveszteség veszi át (Bugár & Rattig, 2016).

A pénzügyi kockázatkezelés a vállalatok szempontjából is nagy jelentőséggel bír. Az értekezésben bemutatott várható többletveszteség (expected shortfall) mutatót többek között a tőzsdei és OTC elszámolóházak (SEC, 2017a) (SEC, 2017b) (SEC, 2019) (NodalClear, 2021) is használják a derivatív pozíciók letéti követelményeinek meghatározásához. Egy elszámolóház fő tevékenysége, hogy a partnerek közötti kockázatot átvállalja, majd a letéti előírások segítségével minimálisra csökkenti azokat. Belátható, hogy egy elszámolóház esetében a módszertanilag megfelelő kockázatkezelés és a kockázatok pontos becslése komoly üzleti előnyt eredményez. A várható többletveszteség mutató erre kiváló lehetőséget biztosít. Jól bizonyítja a téma aktualitását, és azt, hogy a várható többletveszteség módszertant a szakmai közösség is elismeri, hogy a Nodal Exchange amerikai egyesült államokbeli energiatőzsde elszámolását végző Nodal Clear vállalat megnyerte a 2017-es év innovációja díjat a várható többletveszteségalapú letétszámítási módszertan bevezetésével (Risk.net, 2017).

A kockázatkezelés és a kockázati mutatók jelentőségén túl szintén fontos kérdés az, hogy milyen modell alkalmazásával lehet értéküket hatékonyan és pontosan becsülni, hiszen könnyen belátható, hogy a várható többletveszteség használata önmagában nem elég, a hatékony kockázatkezeléshez a megfelelő becslési modell és annak folyamatos visszatesztelése is szükséges. A szakirodalomban számos javaslatot találunk a várható többletveszteség különböző modelljeire. A becslésekre használhatunk többek között historikus szimulációt (Righi & Ceretta, 2015), különböző valószínűségi eloszlásokon alapuló modelleket (Nadarajah, et al., 2015), kvantilis regressziót (Koenker, 2005) vagy GARCH-folyamatokat (Engle, 1982) (Righi & Ceretta, 2015).

A várható többletveszteség (expected shortfall, ES) elterjedésének fontos mérföldköve, hogy Acerbi és Székely (2017) az ES-modellek visszatesztelésére olyan eljárást tett közzé, ami a modellek validitásának ellenőrzését és rangsorolását is lehetővé teszi. Ez azért bír nagy jelentőséggel, mert a várható többletveszteség mutatóval szemben a leggyakrabban felmerülő kritika, hogy az ezen az eljárás alapuló modellek nehezen ellenőrizhetők (Gneiting, 2011). Erre nyújt megoldást az Acerbi-Székely-féle backtesting eljárás. A backtesting eljárás segítségével megállapítható, hogy a rendelkezésre álló modellek közül melyik a legalkalmasabb a mutató pontos előjelzésére.

Szintén releváns kérdés, hogy a korábban leírt modellek mellett milyen új modellezési megközelítés lehet még sikeres. Ezen a területen érdekes lehet a neurális hálók módszertana, illetve annak vizsgálata, hogy az hogyan és milyen eredménnyel adaptálható a várható többletveszteség becslésének problematikájára. Az utóbbi években számos tanulmány bizonyítja, hogy a neurális hálókra alapuló modellek kimagasló eredménnyel alkalmazhatók több tudományterületen is (LeCun, et al., 2015), többek között a genetika (Leung, et al., 2014), a gyógyszerkutatás (Ma, et al., 2015), valamint a beszéd felismerés (Hinton & et al., 2012) területén.

Az elért eredmények ellenére az idősorok előrejelzése már korábban is a nehezen megfogható alkalmazási területek közé tartozott. Yang és Wu (2006) is a terület tíz kihívást jelentő problémája között sorolja fel az idősorok elemzését, elsősorban az adatokat szennyező magas zajszint miatt. Långkvist és szerzőtársai (2014) kiemelik, hogy a jelenleg elért eredmények többnyire az időben statikus adatok feldolgozásában születtek, de az idősorok elemzése is egyre nagyobb figyelmet kap. A kihívások ellenére a gépi tanuláson alapuló megoldások képesek arra, hogy a pénzügyi idősorok nem-lineáris struktúráját modellezzék.

Az irodalomban a neurális hálók módszertanát pénzügyi idősorok területén többnyire a hozam (Galeshchuk, 2016) (Badics, 2014) (Fischer & Krauss, 2018), kisebb mértékben a volatilitás (Lahmiri, 2017) (Kristjanpoller, et al., 2014) előrejelzésére alkalmazzák. Ezek közül a pénzügyi befektetések kockázatának mérésére Markowitz (1952) munkája alapján adódik a variancia használata, de a várható többletveszteség becsléséről is található ilyen jellegű munka (Uzsoki, 2020).

3 Az értekezés felépítése

Az első fejezet a téma jelentőségét mutatja be egyrészt a kockázatkezelés, a várható többletveszteség (expected shortfall) koherens kockázati mérőszám, a 2007-es válság, a Bázeli III. banki keretrendszer és az elszámolóházak szempontjából. Ezt követően a neurális hálózatok eredményeinek áttekintése következik, azzal a felvetéssel, hogy neurális hálók adaptálhatóak a várható többletveszteség becslésére. Az első fejezet második szakasza az értekezés kiinduló hipotéziseit tartalmazza, valamint a disszertáció szerkezetét.

A második fejezet a pénzügyi kockázatméréssel kapcsolatos szakirodalmat tekinti át, kezdve a kockázat pénzügyi definícióival, majd rátérve a kockázatkezelés történeti kezdeteire, a kockázatmérés szükségességére és a kockázatok típusaira. Ezt követően a fejezet áttekinti a koherens kockázati mutatók kritériumait, valamint a gyakorlati szempontból releváns variancia és a maximális visszaesés mutatókat. Ezt követően a fejezet rátér a kockázatos érték mutató bemutatására, ennek hátrányaira, és bemutatja a kockázatos érték hiányosságaira válaszul bevezetett várható többletveszteség kockázati mérőszámot.

A harmadik fejezet a várható többletveszteség és a kockázatos érték mutatók szerepét mutatja be a szabályozásban és a kockázatkezelés gyakorlatában, ezzel is alátámasztva a téma aktualitását. A fejezet első szakasza a Bázeli Bankfelügyeleti Bizottság keretrendszerét (BCBS, 2021) mutatja be, valamint az Európai Unió Solvency II biztosítási szabályozását (Európai Parlament, 2009), végül pedig a svájci Swiss Solvency Test biztosítási szabályozást (Federal Office of Private Insurance, 2006). Ezt követően a harmadik fejezet leírja az amerikai egyesült államokbeli SEC által felügyelt OTC és tőzsdei elszámolóházak ES-mutatóhoz (Rockafellar & Uryasev, 2002) kapcsolódó kockázatmérési gyakorlatát (SEC, 2017a) (SEC, 2017b) (SEC, 2019). A fejezet a Risk.net befektetői kockázatkezelési felmérése releváns eredményeinek bemutatásával zárul (Risk.net, 2020).

A negyedik fejezetben a várható többletveszteség kockázati mutató becslésére alkalmazott statisztikai modellek részletes leírása következik. Elsőként a historikus szimuláció került bemutatásra, majd a különböző valószínűségi eloszlásokon alapuló modellek következnek két részre bontva. Az értekezés elsőként részletesebben azokat a kiemelt eloszlásokat taglalja, amelyek később az eredmények alapján az összesített

rangsor felső negyedébe tartoznak. Ezt követi a jelen kontextusban rosszabb teljesítményű eloszlások kompakt, táblázatba foglalt leírása a számítások reprodukálhatósága végett. A fejezet a GARCH- (Engle, 1982) és a kvantilis regresszió (Koenker & Bassett, 1978) alapú modellek leírásával zárul.

Az ötödik fejezet a neurális hálózatokkal kapcsolatos elméleti háttérrel foglalkozik, valamint a szerző által kifejlesztett új, neurális hálókra alapuló modellt mutatja be. A fejezet elsőként bemutatja a neurális hálózatok kialakulásának főbb mérföldköveit a kezdeti, tanulásra képtelen MCP-neuronmodelltől (McCulloch & Pitts, 1943), a terület nagy áttöréseinek ismertetésén keresztül a jelenleg is használt modern megoldásokig. Az ötödik fejezet ezt követően a modern neurális hálók főbb működési mechanizmusait, illetve a neurális hálók kategorizálásához alkalmazott szempontrendszert írja le. Az ötödik fejezet részletesen leírja a neurális hálók módszertanának központi elemét képező tanítási folyamatot, valamint a modellben hiperparaméterként megjelenő optimalizációs algoritmusok működését. Ezt követően a fejezet bemutatja a túltanulás megakadályozására alkalmazott dropout, azaz a csomópontok véletlenszerű kihagyásának módszertanát, a szintén hiperparaméterként megadott aktivációs függvényeket, valamint a neurális hálók implementációjánál alkalmazott programkönyvtárakat. A fejezet végül a konkrét neurális háló-modell leírásával zárul.

A hatodik fejezet a modellek összehasonlítására használt backtesting módszertant ismerteti. Az eljárás az értekezés szempontjából különösen nagy jelentőséggel bír, mivel ez teszi lehetővé a modellek rangsorolását, valamint az eredmények aggregációját. A fejezet bemutatja az elicitabilitás fogalmát. Ez a tulajdonság egyes tanulmányok szerint a várható többletveszteség modellek nehézkes visszatesztelhetőségét okozza. Ezt követően a fejezet ismerteti a különböző backtesting eljárásokat, azok kialakulását egészen a VaR-alapú (Jorion, 2007) visszatesztelési módszerektől kezdve. Ezek után az értekezésben használt, az elicitabilitás tulajdonságának hiánya ellenére a modellek összehasonlítására és validálására alkalmas visszatesztelési eljárás kerül bemutatásra. A fejezet a visszatesztelési eljárások különböző kiterjesztési lehetőségeinek áttekintésével zárul.

A hetedik fejezet az empirikus elemzést, a neurális háló modell-hiperparamétereinek érzékenységvizsgálatát, valamint az értekezés eredményeit és következtetéseit foglalja össze. A fejezet elsőként az adatokat és azok statisztikai tulajdonságait írja le: az adatok normalitás-ellenőrzésének eredményét, az eloszlások ferdesége és csúcossága tesztelésének, valamint az idősorok stacionaritás-

ellenőrzésének eredményét. Ezután a korábban bemutatott várható többletvesztésmodellek összesített rangsora következik, melyet a két legjobb modell eredményeinek részletes elemzése követ. A fejezet részletesen leírja a hiperparaméterek megválasztásának hatását a modell eredményességére. A fejezetben vizsgált hiperparaméterek: a belső és a kimeneti aktivációs függvények, a becslési és a tesztelési időszak hossza, az optimalizációs eljárás megválasztása és a dropout módszertan során használt csomópontelhagyás valószínűsége. A fejezet az értekezés eredményeivel és következtetéseivel zárul.

4 Az értekezés hipotézisei

Az értekezés a következő munkahipotézisekkel dolgozik:

H1: Érdemes a várható többletveszteség modellezésben az eloszlásfüggvények széles körét tesztelni, mert létezhetnek olyan kevésbé ismert eloszlások, amelyek a klasszikus modellekhez képest lényegesen jobb becsléseket eredményeznek.

H2: Lehetséges olyan neurális hálózat létrehozása, amely alkalmas a várható többletveszteség kockázati mutató előrejelzésére és a többi jól teljesítő modellel összemérhető pontosságú becslést ad.

H3: Neurális hálók segítségével létrehozható olyan modell, amely pontosabb várható többletveszteség-becslést ad, mint kizárólag a statisztikai modellek használata.

H4: A neurális hálózat becslésének pontossága javítható oly módon, hogy a neurális hálózat újratanítását gyakrabban végezzük el.

5 Az értekezés eredményei

H1: Érdemes a várható többletveszteség modellezésben az eloszlásfüggvények széles körét tesztelni, mert létezhetnek olyan kevésbé ismert eloszlások, amelyek a klasszikus modellekhez képest lényegesen jobb becsléseket eredményeznek.

Az értekezésben bemutatott arcsine-eloszláson alapuló modellnél a közismert normális- és a t-eloszláson alapuló modellek több, mint háromszor akkora hibát vétettek, így kijelenthető, hogy fontos és eredményes volt a kevésbé ismert eloszlások teljesítményének tesztelése a várható többletveszteség modellezésének kontextusában.

H2: Lehetséges olyan neurális hálózat létrehozása, amely alkalmas a várható többletveszteség kockázati mutató előrejelzésére és a többi jól teljesítő modellel összemérhető pontosságú becslést ad.

A neurális hálók módszertana alkalmazható a várható többletveszteség kockázati mutató becslésére. A szerző által kifejlesztett és ismertetett megközelítés az arcsine-eloszláson alapuló modell becsléseit korrigálja a tanítási fázisban feldolgozott korábbi megfigyelések alapján.

H3: Neurális hálók segítségével létrehozható olyan modell, amely pontosabb várható többletveszteség-becslést ad, mint kizárólag a statisztikai modellek használata.

A szerző által kifejlesztett arcsine becslését korrigáló neurálisháló-modell szignifikánsan jobb eredményt adott, mint a teljes összehasonításban második helyet elérő arcsine-modell, így kijelenthetjük, hogy a neurális hálók módszertana nem csak adaptálható a várható többletveszteség becslési problémájára, hanem a módszertan alkalmazása a becslések további javítását teszi lehetővé.

H4: A neurális hálózat becslésének pontossága javítható oly módon, hogy a neurális hálózat újratanítását gyakrabban végezzük el.

Értekezésemben megvizsgáltam számos hiperparaméter hatását a neurális hálón alapuló modell teljesítményére. Az egyik hiperparaméter a tartási időszak hossza. A tartási időszak azt adja meg, hogy a neurális háló súlyait milyen hosszú ideig tartjuk meg. A tartási időszak végén a tanítási folyamat megismétlésével a neurális hálózat csomópontjait összekötő élek új súlyokat kapnak, ezáltal a modell összefüggései is megváltoznak. Minél kisebb a tartási időszak hiperparaméter értéke, annál gyakrabban tanul meg új összefüggéseket a modell. Az eredményekből kiderül, hogy a tartási időszak

csökkentése a 12 és a 6 hónap közötti intervallumon az eredmények javulásához vezet. A tartási időszak további csökkentése ezt követően a modell teljesítményének romlását vonja maga után. Az eredmények alapján kijelenthető, hogy a modellezés során érdemes a tartási időszak hatását viszonylag széles intervallumon tesztelni, majd kiválasztani az optimális értéket, mert a hiperparaméter csökkentése nem minden esetben eredményezi a modell javulását.

6 A kutatás továbbfejlesztésének lehetőségei

A várható többletveszteség mutató becslési modelljeivel kapcsolatban több továbblépési lehetőség is felmerül. Egyrésztől érdekesnek tartom a legsikeresebb eloszlásalapú modellek szűk körének vizsgálatát portfólió kontextusban különböző kopolák felhasználásával. Ez a kutatási irány az értekezésben bemutatott rendkívül széles modellpalettával nem megvalósítható, mivel a portfóliókkal kapcsolatban felmerülő szimulációk olyan jelentős számítási igényvel járnak, hogy futtatásuk az elérhető hardverkapacitások mellett éveket vett volna igénybe.

A másik továbblépési lehetőség a neurális hálók továbbfejlesztése az inputidősorok bővítésével. Ez a potenciális kiegészítőadatok elérhetőségének függvényében valószínűleg a feldolgozott idősorok hosszának csökkenését vonja maga után, de könnyen elképzelhető, hogy vannak olyan releváns információkat tartalmazó idősorok, amelyek a neurális hálón alapuló modell becsléseit tovább javítják.

7 A téziszűzetben felhasznált irodalom

Acerbi, C., & Szekely, B. (2017). General properties of backtestable statistics. *Working Paper*, https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2905109. Retrieved from https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2905109

Artzner, P., Delbaen, F., Eber, J.-M., & Heath, D. (1999). Coherent Measures of Risk. 9, 203-228.

Badics, M. (2014). Tőzsdei idősorok előrejelzése adatbányászati módszerekkel. *Hitelintézet Szemle*, 13.(4.), 207-227.

BCBS. (2021, 01 22). *The Basel Framework*. Retrieved 05 09, 2021, from https://www.bis.org/basel_framework/index.htm?export=pdf

Bugár, G., & Rattag, A. (2016). A piaci kockázat számszerűsítésének változása a Bazel III szabályozásban. *Hitelintézet Szemle*, 15. évf. 1. szám, 33–50.

Engle, R. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica*, 50(4), 987-1007.

Európai Parlament. (2009, 11 25). *DIRECTIVE 2009/138/EC*. Retrieved 05 09, 2021, from <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32009L0138>

- Federal Office of Private Insurance. (2006, 10). *Technical document on the Swiss Solvency Test*. Retrieved 01 31, 2021, from https://www.finma.ch/FinmaArchiv/bpv/download/e/SST_techDok_061002_E_wo_Li_20070118.pdf
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions . *European Journal of Operational Research* , 1-16.
- Galeshchuk, S. (2016). Neural networks performance in exchange rate prediction. *Neurocomputing*, 172, 446-452.
- Gneiting, T. (2011). Making and Evaluating Point Forecasts. *106(494)*, 746-762.
- Hinton, G., & et al. (2012). Deep neural networks for acoustic modeling in speech. *IEEE Signal Processing Magazine*, 29, 82-97.
- Jorion, P. (2007). *Value at Risk - The New Benchmark for Managing Financial Risk* (3rd ed.). New York: McGraw-Hill.
- Koenker, R. (2005). *Quantile Regression*. Cambridge: Cambridge University Press.
- Koenker, R., & Bassett, G. (1978). Regression Quantiles. *Econometrica*, 46(1), 33-50.
- Kristjanpoller, W., Fadic, A., & Minutolo, M. C. (2014). Volatility forecast using hybrid Neural Network models. *Expert Systems with Applications*, 41, 2437-2442.
- Lahmiri, S. (2017). Modeling and predicting historical volatility in exchange rate. *Physica*, 387-395.
- Längkvist, M., Karlsson, L., & Loutfi, A. (2014). A review of unsupervised feature learning and deep learning A review of unsupervised feature learning and deep learning. *Pattern Recognition Letters*, 42, 11-24.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521, 436-444.
- Leung, M., Xiong, H., Lee, L., & Frey, B. (2014). Deep learning of the tissue-regulated splicing code. *Bioinformatics*, 30, 121-129.
- Ma, J., Sheridan, R., Liaw, A., Dahl, E., & Svntnik, V. (2015). Deep Neural Nets as a Method for Quantitative Structure–Activity Relationships. *Journal of Chemical Information and Modeling*, 55(2), 263-274.

- Markowitz, H. M. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77-91.
- McCulloch, W., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5, 115-133.
- McNeil, A., Embrechts, P., & Frey, R. (2015). *Quantitative Risk Management* (2nd ed.). New Jersey: Princeton University Press.
- Nadarajah, S., Chan, S., & Afuecheta, E. (2015, 2 19). *Package 'VaRES'*. Retrieved 7 31, 2019, from <https://cran.r-project.org/web/packages/VaRES/VaRES.pdf>
- NodalClear. (2021). *Margin Methodology*. Retrieved 02 02, 2021, from <https://www.nodalexchange.com/nodal-clear/risk-management/margin-methodology/>
- Righi, M. B., & Ceretta, P. (2015). A comparison of Expected Shortfall estimation models. *Journal of Economics and Business*, 78, 14-47.
- Risk.net. (2017). *Clearing house innovation of the year: Nodal Clear*. Retrieved 02 03, 2021, from <https://www.risk.net/awards/2480700/clearing-house-innovation-year-nodal-clear>
- Risk.net. (2020, 07 24). *Before and after the Covid-19 storm: Risk.net's Buy-side Risk Management Survey 2020*. Retrieved 02 10, 2021, from <https://www.risk.net/media/download/1047451>
- Rockafellar, R., & Uryasev, S. (2002). Conditional value-at-risk for general loss distributions. *Journal of Banking & Finance*, 26, 1443-1471.
- SEC. (2017a, 08 15). *Release No. 34-81399; File No. SR-LCH SA-2017-007*. Retrieved 02 02, 2021, from <https://www.sec.gov/rules/sro/lchsa/2017/34-81399.pdf>
- SEC. (2017b, 12 13). *Release No. 34-82313; File No. SR-ICEEU-2017-013*. Retrieved 02 02, 2021, from <https://www.sec.gov/rules/sro/iceeu/2017/34-82313.pdf>
- SEC. (2019, 04 30). *Release No. 34-85755; File No. SR-OCC-2019-004*. Retrieved 02 02, 2021, from <https://www.sec.gov/rules/sro/occ/2019/34-85755.pdf>
- Uzsoki, M. (2020). Neurális hálók a pénzügyi kockázatomérésben. *Sigma*, LI(3), 287-299.

Yang, Q., & Wu, X. (2006). 10 challenging problems in data mining research. *International Journal of Intermination Technology & Decision Making*, 5(4), 597-604.

8 Az értekezés témakörében megjelent saját publikációk

8.1 Hazai és külföldi folyóiratcikkek

Bugár Gy, Uzsoki M. (2021): Kockázatbecslő modellek visszatesztelése. *Sigma*, 52. 2., 149-163

Uzsoki M. (2020): Neurális hálók a pénzügyi kockázاتمérésben, *Sigma* 51. 3., 287-300

Bugár Gy. – Uzsoki M. (2013): Challenges and Achievements in Gauging Investment, *Journal of Transnational Management*, 18. 1., 39-51

Bugár Gy. – Uzsoki M. (2011): Portfolio Optimization Strategies - Performance Evaluation with Respect to Different Objectives. *Journal of Transnational Management*, 16. 3., 135-148

Bugár Gy.- Uzsoki M. (2006): Befektetések kockázatának mérése. *Statisztikai Szemle*, 87/9, 876-898.

Bugár Gy.- Uzsoki M. (2005): Nemzetközi részvény befektetési lehetőségek Közép- és Kelet-Európa új európai uniós tagállamainak szemszögéből. *Közgazdasági Szemle*, 52/6 576–598.

8.2 Műhelytanulmányok

Bugár Gy. – Uzsoki M. (2021): Back-testing risk estimation models: A simulation study for two-asset portfolios. *UPFBE Working Paper Series*, 2021/2

Bugár Gy. – Uzsoki M. (2017): Simulating and Back-Testing Risk Estimation Models. *ASTIN/AFIR-ERM Colloquium Panama City: International Actuarial Association*.

Bugár Gy. – Uzsoki M. (2015): Copula Simulation in Portfolio Allocation Decisions. *ASTIN/AFIR/ERM Sydney, Ausztrália, 2015.08.23-2015.08.27*.

Bugár Gy. – Uzsoki M. (2009): A Longitudinal Study on Portfolio Optimization: Is the “Success” Time Dependent? *Proceedings (CD) of the 19th International AFIR Colloquium*

8.3 Díjat nyert konferenciatanulmányok

Bugár Gy. – Uzsoki M. (2012): Challenges and Achievements in Gauging Investment Risk. *International Management Development Association, Twenty first World Business Congress, Helsinki*

Best Paper Award

Bugár Gy. – Uzsoki M. (2010): Portfolio Optimization Strategies: Performance Evaluation with Respect to Different Objectives. *Proceedings of the 19th Annual World Business Congress of IMDA*

Best Paper Award

8.4 Konferencián tartott előadások

Bugár Gy. – Uzsoki M. (2016): Simulating and Back-testing Portfolio Allocation Decisions. *Financial Market Liquidity Conference, Corvinus University, Budapest.*

Uzsoki M. (2016): Befektetés-kockázati modellek ellenőrzése. *Közgazdász Kutatók és Doktoranduszok III. Téli Konferenciája 2016. január 29. Edutus Főiskola*