

Doktori (PhD) értekezés tézisei

**Idősor-előrejelzés mélytanulással, pénzügyi  
alkalmazásokkal**

**Petneházi Gábor**

*Témavezető:* Dr. Gáll József Mihály, egyetemi docens



DEBRECENI EGYETEM

Matematika- és Számítástudományok Doktori Iskola

Debrecen, 2021.



## 1. Háttér és célkitűzések

A PhD hallgatóként töltött éveim során mélytanulás-alapú idősor-előrejelzéssel foglalkoztam. A mélytanulás mély neurális hálózatok alkalmazását jelenti gépi tanulásban. Mivel az idősor-előrejelzés lényegében tekinthető egy felügyelt tanulási feladatnak, a mélytanulás egy alkalmas eszköz a területen (legalábbis elméletileg).

A neurális hálózatok lenyűgöző eredményeket értek el különféle kihívást jelentő területeken, többek között szekvenciális modellezési feladatokban. Vannak olyan hálózattípusok (rekurrens és konvolúciós hálózatok), melyek különösen jól tudják modellezni az időbeli összefüggéseket. Ennek ellenére úgy tűnik, hogy a mélytanulás módszerei még nem tudtak igazi áttörést hozni az előrejelzések területén.

Az elsődleges célom az volt, hogy találjunk olyan eljárásokat, melyekkel hatékonyan alkalmazhatunk komplex gépi tanulási algoritmusokat idősorok előrejelzésére, és hogy ezek működőképességét igazoljuk hasznos alkalmazásokkal.

Az idősorok nehézséget jelentenek a mélytanulásnak, hiszen azok (többnyire) rövidek. Ez egy komoly hátrány. A mély neurális hálózatok sok optimalizálandó súlyt tartalmaznak, így kevés adattal nem igazán lehet őket tanítani. Izgalmas feladat a megszokottnál jóval kevesebb adattal készíteni predikciókat.

Az értelmezhetőség egy másik probléma. Az idősor-előrejelzés tipikusan egyszerűen értelmezhető modellek és predikciók készítésére törekszik, míg a gépi tanulás a mintán kívüli pontosságra koncentrál, és kevésbé veszi figyelembe a belső mechanizmusokat. A mélytanuló algoritmusokat általában feke-

tedobozként kezeljük: tudjuk, hogy működnek, de nem tudjuk, hogyan. Vagyis hiába tudjuk a rendszer működésének lényegét, a számítások túl bonyolultak ahhoz, hogy emberi aggyal értelmezhesük, így pedig nehéz jelentést tulajdonítani az előrejelzéseknek.

Ezek a markáns eltérések a két (egyébként rokon) terület között izgalmassá és vonzóvá tették számomra ezt a kutatási irányt.

**Publikációk** A disszertáció a következő cikkekre épül. (A cikkek egy része publikálásra került, másik része elérhető preprint formájában.) A *Recurrent Neural Networks for Time Series Forecasting* [Petneházi, 2019b] című cikk ismerteti az empirikus cikkeinkben alkalmazott módszerek jelentős részét. Az *Exploring the predictability of range-based volatility estimators using recurrent neural networks* [Petneházi and Gáll, 2019a] című cikk a volatilitás különböző becsléseinek előrejelezhetőségét vizsgálja mélytanulás segítségével. A *Volatility Forecasting with 1-dimensional CNNs via transfer learning* [Aradi et al., 2020] című cikkben megmutatjuk, hogy az együttesen tanított neurális hálózatok versenyképes volatilitás-előrejelzéseket készíthetnek. A *Quantile Convolutional Neural Networks for Value at Risk Forecasting* [Petneházi, 2019a] című cikk egy konvolúciós neurális hálózaton alapuló megközelítést javasol a Value-at-Risk előrejelzésére. Az *Evaluating the Lee-Carter model on Hungarian mortality data* [Petneházi and Gáll, accepted] című cikk a Lee-Carter mortalitási ráta előrejelző modell egy alkalmazását ismerteti, míg a *Mortality rate forecasting*:

*can recurrent neural networks beat the Lee-Carter model?* [Pete-neházi and Gáll, 2019b] című cikk rekurrens neurális hálózatok segítségével készít hosszútávú mortalitási ráta előrejelzéseket a világ számos országára.

**Pénzügy** A pénzügy érdekes előrejelzési feladatokat szolgáltat: sokféle adatállománnyal és sokféle problémával foglalkozhatunk. Találhatunk kicsi adatot és nagy adatot, találhatunk állítólagosan előrejelezhető és állítólagosan előrejelezhetetlen mechanizmusokat, mindezt igen bőséges tudományos irodalommal körítve. A legtöbb pénzügyi előrejelzési feladat komoly gyakorlati jelentőséggel bír, ami nagy mértékű kutatási erőfeszítést vonz a területre. Mindig nagy a verseny. Ez a környezet nagyon kedvező új technológiák, új módszerek alkalmazására.

**Struktúra** A disszertáció két nagy fejezetből áll. Az első bemutatja a mélytanulást, és tárgyalja a legfontosabb megfontolásokat annak idősor-előrejelzésre való alkalmazása kapcsán. A második fejezet bemutatja az empirikus tanulmányainkat a pénzügyi előrejelzések területén (mortalitási ráták előrejelzése és kockázat előrejelzése).

## 2. Módszerek

Az első fejezet ismerteti a mélytanulás-alapú idősor-előrejelzés módszertanát. A fejezet első része bemutatja a mélytanulás működését, illetve két olyan hálózattípust, amik

különösen alkalmasak idősor-előrejelzésre (rekurrens és konvolúciós hálózatok). A fejezet második része az idősor-előrejelzési projektek legfontosabb követelményeit ismerteti, illetve olyan gyakorlatokat, melyek segíthetik a mélytanulási módszereket megfelelni az elvárásoknak.

## 2.1. Mélytanulás

A „mélytanulás” elnevezés olyan gépi tanulási módszereket takar, melyek több rétegű neurális hálózatokat használnak. Van két olyan speciális hálózattípus, melyek eredendően jól tudnak modellezni szekvenciális adatokat. A rekurrens neurális hálózatok (RNN) memóriát építenek, és a korábbi státuszaikat is használják döntéseik meghozatalához. A konvolúciós neurális hálózatok (CNN) csúsztatott megosztott súlyokat használnak a helyi mintázatok felismeréséhez. A kapuk által vezérelt rekurrens egységek [LSTM [Hochreiter and Schmidhuber, 1997], GRU [Cho et al., 2014]] és a dilatált [Yu and Koltun, 2015] kauzális [Oord et al., 2016] konvolúciós neurális hálózatok versenyképes eredményeket szállítottak különféle szekvenciális tanulási feladatok esetén, azonban az idősor-előrejelzés területén még nem lettek teljes mértékben kiaknázva a módszerekben rejlő lehetőségek.

**Előrejelzés rekurrens hálózatokkal** Gers et al. [2002] összehasonlította egy LSTM és egy hagyományos előrecsatolt neurális hálózat előrejelzési teljesítményét, és azt találta, hogy az előbbi alkalmazása akkor lehet előnyös, amikor utóbbi csődöt mond. A rekurrens neurális hálózatok újabb alkalmazásaira

példa Guo et al. [2016], Fu et al. [2016], Qin et al. [2017], vagy éppen Salinas et al. [2020].

**Előrejelzés konvolúciós hálózatokkal** Habár a konvolúciós neurális hálózatokat alapvetően képfeldolgozásban használják, idősor-előrejelzésben is nagy múlttal rendelkeznek. Az időkésleltetett neurális hálózatok [Lang et al., 1990], melyek időbeli mintázatok osztályozására lettek kifejlesztve, lényegében az első konvolúciós hálózatok voltak. Újabban, a dilatált architektúrák előretörése fellendítette az idősor-előrejelzési alkalmazásokat. Borovykh et al. [2017] és Chen et al. [2020] jó példák dilatált kauzális neurális hálózatok idősoros alkalmazására.

## 2.2. Mély idősor-előrejelzés

A hagyományos gépi tanulási megoldások tipikusan nem felelnek meg az idősor-előrejelzés bizonyos elvárásainak. Az egyik ilyen elvárás a bizonytalanság számszerűsítése. A felügyelt tanulás egyetlen célja az, hogy pontos (mintán kívüli) pontpredikciókat készítsen, vagyis hogy a becslések minél közelebb legyenek a célzott értékekhez. Ennek megfelelően a mély neurális hálózatok általában csak pontbecsléseket készítenek anélkül, hogy számszerűsítsék a döntéseikben rejlő bizonytalanságot. Ez a hiányosság kezelhető bootstrapping vagy kvantilis regresszió alkalmazásával, mely módszerek segítségével intervallum előrejelzéseket készíthetünk. Egy további probléma az értelmezhetőség: a neurális hálózatok különösen nehezen interpretálhatók. Habár elérhetetlen célnak tűnik az, hogy tökéletesen

megértsük a hálózatok működését, a bemeneti változók fontosságát tudjuk számszerűsíteni, és ez már önmagában sokat javíthat az értelmezhetőségen. Az elérhető adatok mennyisége szintén egy gyakori probléma, hiszen a mélytanuló algoritmusok tanításához nagy mennyiségű adatra van szükség. Itt az átviteli tanulás nyújthat segítséget, vagyis egy olyan eljárás, ami egyszerre több idősor adataiból képes tanulni. Az idősor-előrejelzésnek vannak további sajátosságai, melyeket figyelembe kell vennünk például a változók tervezése vagy éppen az eredmények értékelése során. Ezeket a szempontokat tárgyalja a disszertáció első és alkalmazza annak második fejezete.

**Feladatok** A disszertáció alapját képező elemzések két intenzíven kutatott területen alkalmazzák a mélytanulás-alapú előrejelző módszereket: pénzügyi kockázat (pontosabban: volatilitás és Value-at-Risk) előrejelzése, illetve mortalitási ráták előrejelzése.

**Kockázat** A volatilitás (vagyis a hozamok változékonysága) előrejelzése nagy múlttal és kiterjedt szakirodalommal rendelkezik. Poon and Granger [2003] egy terjedelmes cikkben ismerteti a terület irodalmát. Habár a volatilitás-előrejelzések tipikusan hagyományos módszerekkel (pl.: ARCH-típusú modellekkel, Engle [2001]) készülnek, a neurális hálózatok alkalmazása nem újdonság a területen (pl., Malliaris and Salchenberger [1996], Donaldson and Kamstra [1996]). Dunis and Huang [2002] rekurrens neurális hálózatokat alkalmazott a területen. Xiong et al. [2015] LSTM és külső

(keresési) adatok segítségével túlmuta felül a hagyományos modelleket.

A Value-at-Risk értékét (vagyis a nyereség egy meghatározott kvantilisét) becsülhetjük előrejelzett volatilitásból, amennyiben megfelelő feltételezésünk van a hozamok eloszlására vonatkozóan, vagy pedig közvetlenül előrejelezhetjük kvantilis regresszió segítségével. Ez utóbbi módszer is támogatható mélytanulással. Taylor [2000] egy kvantilis regressziós neurális hálózatot alkalmazott. Yan et al. [2018] LSTM hálózatot használt egy kvantilis függvényel Value-at-Risk predikciók készítésére.

**Mortalitás** A mortalitási ráták előrejelzésének területén szintén alapvetően egyszerűbb matematikai modellek dominálnak. A Lee-Carter modell [Lee and Carter, 1992] a mortalitási ráták mátrixát jelzi előre. Bár a mortalitási ráták értékeit ritkán jegyzik (és így az elérhető halandósági táblázatok kicsik), mégsem példa nélküli a mélytanulás alkalmazása a területen. Shah and Guez [2009] neurális hálózatokat alkalmazott ok-specifikus halálozási adatokra. Richman and Wuthrich [2018] kiterjesztette a Lee-Carter modellt több populációra, neurális hálózatok segítségével. Werpachowska [2018] brit mortalitási rátákat jelzett előre rekurrens neurális hálózatokkal.

### 3. Eredmények

A második fejezet bemutatja az eredményeit a mélytanulás-alapú előrejelzési tanulmányainknak. A elemzések két ka-

tegóriába sorolhatók: pénzügyi kockázat előrejelzése, és mortalitási ráták előrejelzése.

### 3.1. Terjedelemalapú volatilitás-becslések változási irányának előrejelzése

A részvényárfolyamok volatilitása (elméletileg) előrejelezhető. A volatilitás azonban nem megfigyelhető, valamilyen módon becsülnünk kell. A terjedelemalapú volatilitás-becsléseket ritkán alkalmazzák, előnyös tulajdonságaik ellenére. Azt vizsgáltuk, hogy a volatilitás különböző becslései milyen mértékben igazolják az előrejelezhetőséget. Elsősorban a változások irányának előrejelzésére fókuszáltunk. Egy neurális hálózatot alkalmaztunk LSTM egységekkel annak előrejelzésére, hogy a volatilitás-becslések értéke növekszik vagy éppen csökken egyik napról a másikra. 29 gyakran kereskedett részvényhez készítettünk előrejelzéseket egy 3 éves időszakra, és azt találtuk, hogy **a terjedelemalapú becslések jobban előrejelezhetők mint a klasszikus, csak záró árfolyamokat használó becslés** (1. táblázat). Azonban (ésszerűen) módosított becsléseket vizsgálva vagy a volatilitás értékét előrejelezve már sokkal kevésbé tapasztaltuk ezeket az eltéréseket.

### 3.2. Volatilitás-előrejelzés átviteli tanulással

A részvényárfolyamok mutatnak olyan közös tulajdonságokat, melyek alapján érdemes lehet több részvény árfolyamtörténetét együttesen használni algoritmusok

	Pontosság		Precizitás		Felidőzés	
	átlag	szórás	átlag	szórás	átlag	szórás
close-to-close	0.50	0.02	0.50	0.01	<b>0.88</b>	0.16
Garman-Klass	<b>0.58</b>	0.03	0.59	0.03	0.49	0.09
Parkinson	<b>0.58</b>	0.02	<b>0.60</b>	0.03	0.46	0.09
Rogers-Satchell	0.57	0.02	0.58	0.03	0.45	0.10
Yang-Zhang	<b>0.58</b>	0.02	0.59	0.03	0.47	0.10

1. táblázat. Értékelési mérőszámok az előrejelzett volatilitás-irányokra. (A hagyományos close-to-close becslést, illetve 4 különböző terjedelemalapú becslést alkalmazva.)

tanításához. Azt tanulmányoztuk, hogy egy együttesen tanított neurális hálózat képes lehet-e jobb eredményeket szállítani mint az egyedileg tanított modellek. (Itt a volatilitást a hozamok egy mozgó szórásával becsültük.) Egy dimenziós dilatált kauzális konvolúciós neurális hálózatot tanítottunk több száz részvény volatilitás-történetét felhasználva, kihagyva azonban azokat a részvényeket, melyek előrejelzésével próbálkoztunk. Vagyis az előrejelző algoritmus a tanítás során nem is találkozott azokkal a részvényekkel, melyeket előrejelezni volt hivatott. Ezt az együttesen tanított modellt vetettük össze egy egyedileg tanított konvolúciós hálózattal és egy ARIMA modellel. Az átviteli tanulós megközelítés egyértelműen jobb eredményeket hozott mint az összehasonlításul használt módszerek, mind a volatilitás irányának, mind a volatilitás értékének előrejelzésében. Az eredmények azt mutatják, hogy **az együttesen tanított neurális hálózatok jó volatilitás-előrejelzéseket készíthetnek**, ez pedig lényegesen bővítheti

a mélytanulás alkalmazási lehetőségeit a területen.

### 3.3. A volatilitás stilizált tényeinek vizsgálata

A stilizált tények szerint a volatilitás kapcsolatos a hozamokkal, kereskedési volumenekkel, és bizonyos külső tényezőkkel is. Azt próbáltuk vizsgálni, hogy az állítólagos kapcsolatok valóban léteznek-e. LSTM hálózatot használtunk, több bemeneti változóval. A modelleket bootstrap mintavételezett részein tanítottuk a volatilitás idősorának. A bootstrapping segítségével stabilabb előrejelzéseket tudtunk készíteni, mérni tudtuk a predikciók bizonytalanságát, és számszerűsíteni tudtuk a változók fontosságát. Úgy találtuk, hogy **a volatilitás és a hozam fontos előrejelzője a jövőbeli volatilitásnak**. A kereskedés volumenét kevésbé találtuk fontos tényezőnek a modellben.

### 3.4. Value-at-Risk előrejelzése kvantilis konvolúciós neurális hálózatokkal

Egy együttesen tanított egy dimenziós dilatált kauzális konvolúciós neurális hálózatot használtunk a Value-at-Risk előrejelzésére. (A Value-at-Risk a hozameloszlás egy kvantilise: egy olyan veszteség, aminél nagyobb veszteség csak egy előre megadott alacsony valószínűséggel következik be.) A "flipper" veszteségfüggvényt használtuk, hogy előrejelezhessük a vizsgált kvantilist, a nyers hozamokat használva bemeneti változóként. Egy napos Value-at-Risk előrejelzéseket készítettünk 100 egyesült államokbeli részvényhez, 3 különböző konfidencia szinttel. Többféle előrejelzéssel versenyeztettük a javasolt modellt:

használtunk lineáris kvantilis regressziót, egy GARCH modellt, egy konstans kvantilis becslést és egy egyedileg tanított konvolúciós hálózatot is. Bár több modell is meglehetősen pontos túllépési arányokat produkált, a javasolt kvantilis konvolúciós neurális hálózat tipikusan kisebb Value-at-Risk értékeket produkált. A dinamikus kvantilis teszt szintén azt mutatta, hogy **az együttesen tanított hálózatunk jobb előrejelzéseket szállított mint a többi vizsgált modell.**

### 3.5. Mortalitás előrejelzése rekurrens neurális hálózatokkal

Egy különálló elemzésben megvizsgáltuk a Lee-Carter mortalitás-előrejelző modell teljesítményét. Ez egy nagyon széleskörűen alkalmazott és elfogadott módszer a területen. Azonban korábbi kutatások szerint a modell nem teljesít jól olyan országok esetén, melyek valamilyen mortalitási sokkon mentek keresztül, mint például a Magyarországhoz hasonló posztszocialista országok. Baran et al. [2007] korábban azt találta, hogy a Lee-Carter modell egy többtényezős verzióját használva, és a rendszerváltás előtti adatokat kihagyva az elemzésből észszerűbb előrejelzések kaphatók. Mi azt találtuk, hogy most, mikor már több múltbeli mortalitási adat áll rendelkezésünkre, **az eredeti Lee-Carter modell alkalmazhatóbbá válik**, de a rendszerváltás előtti adatok elhagyása a modelltől továbbra is előnyös. A Lee-Carter modellt viszonyítási alapként használtuk következő elemzésünkben, melyben mélytanuló algoritmust építettünk a mortalitás előrejelzésére.

Az együttesen tanított mélytanulási megközelítésünket alkalmaztuk mortalitási ráták előrejelzésére is. Ez egy nehéz feladat, hiszen a nyilvántartott mortalitási ráták idősorai rövidek, és általában hosszútávú előrejelzések készítése szükséges. Habár az egyedi idősorok rövidek, több hasonló idősor áll rendelkezésre, így már hagyományosnak mondható módszerek is használnak egyszerre több idősort a modellek illesztéséhez. A széles körben alkalmazott Lee-Carter modell egy általános mortalitási trendet keres az adatokban, ami érvényes minden korcsoportra. Mi egy rekurrens neurális hálózatot használtunk, ami hasonlóképpen több korcsoport mortalitási adataiból tanul, de kiterjeszhető a két nem, illetve különböző országok adatainak használatára is. 10 éves rekurzív előrejelzéseket készítettünk 35 országra, és összehasonlítottuk a Lee-Carter modell és a neurális hálózat predikcióit többféle mérőszám használatával. A rekurrens neurális hálózat jobbnak bizonyult, különösen amikor az összes ország adatain tanítottuk. **A javasolt modell jelentősen jobban teljesített az alap Lee-Carter modellnél.** A Lee-Carter modell néhány kibővített változata már versenyképesebbnek bizonyult, de még azok is alulmúlták a legtöbb neurális hálózatunkat. Az eredmények azt mutatják, hogy bár a mortalitási ráták kevés adatot képeznek, a komplex mélytanulási módszerek sikerrel alkalmazhatók és hasznos előrejelzéseket készíthetnek (2. táblázat).

mérőszám	LC	LSTM Country	LSTM World	LSTM Coed
RMSE	0.0115	0.0076	0.0058	0.0055
MAE	0.0109	0.0069	0.0051	0.0047
MedAE	0.0108	0.0067	0.0049	0.0045
SMAPE	24.85	18.02	15.82	20.76
ME	0.0085	0.0027	0.0037	0.0026

2. táblázat. Átlagos értékelési mérőszámok az előrejelzett mortalitásra. (LC: Lee-Carter modell; LSTM Country: LSTM modell egy országon tanítva; LSTM World: LSTM modell az összes országon tanítva; LSTM Coed: LSTM modell az összes ország és mindkét nem adatain tanítva)

## 4. Következtetések

Kutatásaink célja az volt, hogy áthidaljuk a mélytanulás és az idősor-előrejelzés területei között lévő szakadékot, és hogy a módszerek működőképességét hasznos alkalmazásokkal igazoljuk. Különböző pénzügyi előrejelzéseket készítettünk rekurrens és konvolúciós neurális hálózatok alkalmazásával. A mélytanulás-alapú előrejelzés nem újdonság, de nem is nagyon elterjedt, hiszen vannak hátráltató tényezők, mint például az adatmennyiség vagy éppen a modellek értelmezhetősége. Azt próbáltuk megmutatni, hogy ezek a nehézségek orvosolhatók, és sikerült versenyképes (vagy legalábbis biztató) eredményeket szállítanunk különböző előrejelzési feladatokhoz. Reméljük, hogy a modellek és módszerek hasznosnak fognak bizonyulni, és hogy sikerült hozzájárulnunk ennek az érdekes kutatási területnek a fejlődéséhez.

## Tudományos munkásság

- Petneházi, G., & Gáll, J. (2019). Exploring the predictability of range-based volatility estimators using recurrent neural networks. *Intelligent Systems in Accounting, Finance and Management*, 26(3), 109-116., <https://onlinelibrary.wiley.com/doi/full/10.1002/isaf.1455>.
- Petneházi, G., & Gáll, J. (2022). Evaluating the Lee-Carter model on Hungarian mortality data, *Acta Oeconomica*, közlésre elfogadva.
- Aradi, B., Petneházi, G., & Gáll, J. (2020). Volatility Forecasting with 1-dimensional CNNs via transfer learning. arXiv preprint arXiv:2009.05508., <https://arxiv.org/abs/2009.05508>.
- Petneházi, G. (2019). Quantile Convolutional Neural Networks for Value at Risk Forecasting. arXiv preprint arXiv:1908.07978., <https://arxiv.org/abs/1908.07978>.
- Petneházi, G., & Gáll, J. (2019). Mortality rate forecasting: can recurrent neural networks beat the Lee-Carter model?. arXiv preprint arXiv:1909.05501., <https://arxiv.org/abs/1909.05501>.
- Petneházi, G. (2019). Recurrent neural networks for time series forecasting. arXiv preprint arXiv:1901.00069., <https://arxiv.org/abs/1901.00069>.

## Hivatkozások

- Bernadett Aradi, Gábor Petneházi, and József Gáll. Volatility forecasting with 1-dimensional cnns via transfer learning. *arXiv preprint arXiv:2009.05508*, 2020.
- Sándor Baran, József Gáll, Márton Ispány, and Gyula Pap. Forecasting hungarian mortality rates using the Lee-Carter method. *Acta Oeconomica*, 57(1):21–34, 2007.
- Anastasia Borovykh, Sander Bohte, and Cornelis W Oosterlee. Conditional time series forecasting with convolutional neural networks. *arXiv preprint arXiv:1703.04691*, 2017.
- Yitian Chen, Yanfei Kang, Yixiong Chen, and Zizhuo Wang. Probabilistic forecasting with temporal convolutional neural network. *Neurocomputing*, 2020.
- Kyunghyun Cho, Bart Van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014.
- R Glen Donaldson and Mark Kamstra. Forecast combining with neural networks. *Journal of Forecasting*, 15(1):49–61, 1996.
- Christian L Dunis and Xuehuan Huang. Forecasting and trading currency volatility: An application of recurrent neural regression and model combination. *Journal of forecasting*, 21(5): 317–354, 2002.

- Robert Engle. Garch 101: The use of arch/garch models in applied econometrics. *Journal of economic perspectives*, 15(4):157–168, 2001.
- Rui Fu, Zuo Zhang, and Li Li. Using lstm and gru neural network methods for traffic flow prediction. In *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, pages 324–328. IEEE, 2016.
- Felix A Gers, Douglas Eck, and Jürgen Schmidhuber. Applying lstm to time series predictable through time-window approaches. In *Neural Nets WIRN Vietri-01*, pages 193–200. Springer, 2002.
- Tian Guo, Zhao Xu, Xin Yao, Haifeng Chen, Karl Aberer, and Koichi Funaya. Robust online time series prediction with recurrent neural networks. In *2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, pages 816–825. Ieee, 2016.
- Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, 1997.
- Kevin J Lang, Alex H Waibel, and Geoffrey E Hinton. A time-delay neural network architecture for isolated word recognition. *Neural networks*, 3(1):23–43, 1990.
- Ronald D Lee and Lawrence R Carter. Modeling and forecasting us mortality. *Journal of the American statistical association*, 87(419):659–671, 1992.

- Mary Malliaris and Linda Salchenberger. Using neural networks to forecast the s&p 100 implied volatility. *Neurocomputing*, 10(2):183–195, 1996.
- Aaron van den Oord, Sander Dieleman, Heiga Zen, Karen Simonyan, Oriol Vinyals, Alex Graves, Nal Kalchbrenner, Andrew Senior, and Koray Kavukcuoglu. Wavenet: A generative model for raw audio. *arXiv preprint arXiv:1609.03499*, 2016.
- Gábor Petneházi. Quantile convolutional neural networks for value at risk forecasting. *arXiv preprint arXiv:1908.07978*, 2019a.
- Gábor Petneházi. Recurrent neural networks for time series forecasting. *arXiv preprint arXiv:1901.00069*, 2019b.
- Gábor Petneházi and József Gáll. Exploring the predictability of range-based volatility estimators using recurrent neural networks. *Intelligent Systems in Accounting, Finance and Management*, 26(3):109–116, 2019a.
- Gábor Petneházi and József Gáll. Mortality rate forecasting: can recurrent neural networks beat the Lee-Carter model? *arXiv preprint arXiv:1909.05501*, 2019b.
- Gábor Petneházi and József Gáll. Evaluating the Lee-Carter model on hungarian mortality data. *Acta Oeconomica*, accepted.
- Ser-Huang Poon and Clive WJ Granger. Forecasting volatility in financial markets: A review. *Journal of economic literature*, 41(2):478–539, 2003.

- Yao Qin, Dongjin Song, Haifeng Chen, Wei Cheng, Guofei Jiang, and Garrison Cottrell. A dual-stage attention-based recurrent neural network for time series prediction. *arXiv preprint arXiv:1704.02971*, 2017.
- Ronald Richman and Mario V Wuthrich. A neural network extension of the Lee-Carter model to multiple populations. *Available at SSRN 3270877*, 2018.
- David Salinas, Valentin Flunkert, Jan Gasthaus, and Tim Januschowski. Deepar: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting*, 36(3):1181–1191, 2020.
- Paras Shah and Allon Guez. Mortality forecasting using neural networks and an application to cause-specific data for insurance purposes. *Journal of Forecasting*, 28(6):535–548, 2009.
- James W Taylor. A quantile regression neural network approach to estimating the conditional density of multiperiod returns. *Journal of Forecasting*, 19(4):299–311, 2000.
- Agnieszka Werpachowska. Forecasting the impact of state pension reforms in post-brexit england and wales using microsimulation and deep learning. *arXiv preprint arXiv:1802.09427*, 2018.
- Ruoxuan Xiong, Eric P Nichols, and Yuan Shen. Deep learning stock volatility with google domestic trends. *arXiv preprint arXiv:1512.04916*, 2015.

Xing Yan, Weizhong Zhang, Lin Ma, Wei Liu, and Qi Wu. Parsimonious quantile regression of financial asset tail dynamics via sequential learning. In *Advances in Neural Information Processing Systems*, pages 1575–1585, 2018.

Fisher Yu and Vladlen Koltun. Multi-scale context aggregation by dilated convolutions. *arXiv preprint arXiv:1511.07122*, 2015.





Nyilvántartási szám: DEENK/345/2021.PL  
Tárgy: PhD Publikációs Lista

Jelölt: Petneházi Gábor

Doktori Iskola: Matematika- és Számítástudományok Doktori Iskola

MTMT azonosító: 10069252

### **A PhD értekezés alapjául szolgáló közlemények**

#### Idegen nyelvű tudományos közlemények hazai folyóiratban (1)

1. **Petneházi, G.**, Gáll, J.: Evaluating the Lee-Carter model on Hungarian mortality data.  
*Acta Oecon. "Accepted by Publisher"* (-), 1-12, 2021. ISSN: 0001-6373.  
IF: 0.914 (2019)

#### Idegen nyelvű tudományos közlemények külföldi folyóiratban (1)


2. **Petneházi, G.**, Gáll, J.: Exploring the predictability of range-based volatility estimators using recurrent neural networks.  
*Intell Sys Acc Fin Mgmt.* 26 (3), 109-116, 2019. ISSN: 1055-615X.  
DOI: <http://dx.doi.org/10.1002/isaf.1455>

**A közlő folyóiratok összesített impakt faktora: 0,914**

**A közlő folyóiratok összesített impakt faktora (az értekezés alapjául szolgáló közleményekre):  
0,914**

A DEENK a Jelölt által az iDEa Tudóstérbe feltöltött adatok bibliográfiai és tudánymetriai ellenőrzését a tudományos adatbázisok és a Journal Citation Reports Impact Factor lista alapján elvégezte.

Debrecen, 2021.06.03.





Short thesis for the degree of doctor of philosophy (PhD)

# Deep Learning for Time Series Forecasting with Applications to Finance

by Gábor Petneházi

*Supervisor:* József Mihály Gáll, PhD, associate professor



UNIVERSITY OF DEBRECEN  
Doctoral School of Mathematical and Computational Sciences  
Debrecen, 2021.



# 1 Background and Objectives

During my years as a PhD student, I have been working on deep learning-based time series forecasting. Deep learning means the application of deep neural networks to machine learning. Since time series forecasting can be considered an example of supervised learning, it is a suitable task for deep learning—at least, in theory.

Neural networks have delivered impressive results for various challenging tasks, including sequence modeling problems. There are certain architectures (recurrent and convolutional networks) that can learn temporal dependences particularly well. Yet, they did not seem to have brought a breakthrough in forecasting.

My primary goal was to find ways to efficiently apply powerful machine learning algorithms to time series forecasting, and to demonstrate their functionality with useful applications.

Time series are difficult for deep learning, because they are (typically) short. It is a serious deterrent. Deep neural networks have so many weights, they can hardly be trained with small data. It is an exciting task to produce predictions with much less data than usual.

Interpretability is another issue. Time series forecasting generally aims to produce easy-to-interpret models and predictions, while machine learning focuses on out-of-sample accuracy, less considering the internal mechanisms. Deep learning algorithms are usually considered black boxes—we know if they work well, but we don't know how. Assigning some meaning to the predictions is another challenge.

These striking differences between these two closely related

fields made this research direction very attractive to me.

**Publications** The thesis is based on the following articles. (Some of them have been published, others are available as manuscripts.) *Recurrent Neural Networks for Time Series Forecasting* [Petneházi, 2019b] covers a large part of the methodology that was applied in our empirical studies. *Exploring the predictability of range-based volatility estimators using recurrent neural networks* [Petneházi and Gáll, 2019a] is a comparative study on the forecastability of different volatility estimates. *Volatility Forecasting with 1-dimensional CNNs via transfer learning* [Aradi et al., 2020] explores if jointly trained neural networks can produce competitive volatility forecasts. *Quantile Convolutional Neural Networks for Value at Risk Forecasting* [Petneházi, 2019a] suggests a convolutional neural network-based method for forecasting Value-at-Risk. *Evaluating the Lee-Carter model on Hungarian mortality data* [Petneházi and Gáll, accepted] describes an application of the mortality forecasting Lee-Carter model, while *Mortality rate forecasting: can recurrent neural networks beat the Lee-Carter model?* [Petneházi and Gáll, 2019b] uses recurrent neural networks to produce long-term mortality rate forecasts for several countries of the world.

**Finance** Finance provides interesting forecasting tasks. There are various datasets and various problems. We can find small data, and we can find big data, and we can find supposedly predictable, and supposedly unpredictable mechanisms—all with a large scientific literature. Most financial forecasting problems

are of great practical importance, which brings intensive research to the field. There is always a great competition. This environment is very favorable for applying new technologies, new methods.

**Structure** The dissertation consists of two main chapters. The first one introduces deep learning, and discusses the most important considerations regarding its application to time series forecasting. The second one describes our empirical studies in the field of financial forecasting (mortality rate forecasting and risk forecasting).

## 2 Methods

The first chapter of the dissertation describes the methodology of deep learning-based time series forecasting. The first part of the chapter covers the mechanisms behind deep neural networks together with two architectures that are particularly well-suited to time series forecasting (recurrent and convolutional networks). The second part of the chapter discusses the most common requirements of time series forecasting projects, and some practices that can help deep learning meet the expectations.

### 2.1 Deep Neural Networks

The term "deep learning" covers machine learning methods using multi-layer neural networks. Two particular neural

network architectures have inherent ability to learn sequential data. Recurrent neural networks (RNN) build memory, and use their previous states to make predictions. Convolutional neural networks (CNN) use slided shared weights to find local patterns. Gated recurrent units [LSTM [Hochreiter and Schmidhuber, 1997], GRU [Cho et al., 2014]], and dilated [Yu and Koltun, 2015] causal [Oord et al., 2016] convolutional neural networks have delivered state-of-the-art solutions for various sequential learning problems, but are not yet fully exploited for time series forecasting.

**Forecasting with Recurrent Networks** Gers et al. [2002] compared the forecasting performance of LSTM and a feedforward network, and found that the former can have an advantage when simple traditional models fail. More recent examples of recurrent neural network-based time series forecasting include Guo et al. [2016], Fu et al. [2016], Qin et al. [2017], and Salinas et al. [2020].

**Forecasting with Convolutional Networks** While CNNs are most commonly used in computer vision, CNN-based time series forecasting also has a long history. Time delay neural networks [Lang et al., 1990], developed for temporal pattern classification, were essentially the first convolutional networks. More recently, the advancement of dilated architectures gave a boost to time series forecasting applications. Borovykh et al. [2017] and Chen et al. [2020] are examples of dilated causal convolutional forecasters.

## 2.2 Deep Time Series Forecasting

Traditional machine learning fails to satisfy certain requirements of time series forecasting. One such requirement is the quantification of uncertainty. The single goal of supervised learning is to make accurate (out-of-sample) point predictions, to get as close to the target values as possible. Accordingly, deep neural networks typically produce point predictions only, without any measure of confidence. This deficiency might be remedied by using bootstrapping or quantile regression to produce prediction intervals. Another unmet requirement is interpretability—neural networks are particularly difficult to interpret. While a complete understanding of the networks' operation seems unattainable, the importance of input features can be quantified, and may be quite valuable. The size of available time series data is often a difficulty, since deep learning algorithms need large amounts of data. This might be addressed by using transfer learning, that is, by acquiring knowledge from multiple time series. Time series forecasting also has some peculiar requirements regarding feature engineering and model evaluation. All these considerations are discussed in the first chapter, and are applied in the second.

**Problems** The studies behind this thesis apply deep learning-based forecasting techniques to two intensively researched areas: financial risk forecasting (namely, volatility and Value-at-Risk forecasting), and mortality rate forecasting.

**Risk** Volatility (i.e., the variability of returns) forecasting has a long history and a great literature. See Poon and Granger [2003] for an extensive review. While volatility predictions are generally produced with traditional forecasting techniques (such as ARCH-type models, Engle [2001]), the use of neural networks is not a novelty (e.g., Malliaris and Salchenberger [1996], Donaldson and Kamstra [1996]). Dunis and Huang [2002] applied recurrent neural networks in the field. Xiong et al. [2015] used LSTMs and external (search volume) data to outperform traditional models.

Value-at-Risk (i.e., a chosen quantile of the returns) can be computed from volatility forecasts with distributional assumptions, or it can be forecasted directly with quantile regression. The latter approach, too, may be enhanced with deep learning. Taylor [2000] applied a quantile regression neural network. Yan et al. [2018] used LSTM with a quantile function to produce VaR-forecasts.

**Mortality** Mortality rate forecasting is another field dominated by simple mathematical models. The Lee-Carter model [Lee and Carter, 1992] makes forecasts for a matrix of mortality rates. It is often used as a benchmark to evaluate other forecasting models. Even though mortality rates are rarely observed (so the available life tables are rather small) deep learning have already been applied in the field. Shah and Guez [2009], for example, applied neural networks to cause-specific mortality data. Richman and Wuthrich [2018] extended the Lee-Carter model to multiple populations with neural networks. Werpachowska

[2018] forecasted UK mortality rates with recurrent neural networks.

## 3 Results

The second chapter describes the results of our deep learning-based financial forecasting studies. Our studies can be divided into two main categories: financial risk forecasting, and human mortality rate forecasting.

### 3.1 Directional Forecasts of Range-Based Volatility Estimates

Volatility is unobservable, so we need to estimate it somehow. Range-based volatility estimates are rarely used despite their advantageous properties. Since, in theory, stock price volatility is forecastable, we aimed to compare the degree to which the different volatility estimates can be predicted. We primarily aimed to make and compare directional forecasts. We used a neural network with long short-term memory units to forecast whether the volatility estimates increase or decrease from one day to the other. Having analyzed 29 frequently traded stocks, and having compared the forecasts on a 3-year period, we found that **the directions of range-based volatility changes are clearly more predictable than those of the close-to-close volatility** (Table 1). However, considering value forecasts and some modified estimators, the differences in predictability are less clear.

	Accuracy		Precision		Recall	
	mean	std	mean	std	mean	std
close-to-close	0.50	0.02	0.50	0.01	<b>0.88</b>	0.16
Garman-Klass	<b>0.58</b>	0.03	0.59	0.03	0.49	0.09
Parkinson	<b>0.58</b>	0.02	<b>0.60</b>	0.03	0.46	0.09
Rogers-Satchell	0.57	0.02	0.58	0.03	0.45	0.10
Yang-Zhang	<b>0.58</b>	0.02	0.59	0.03	0.47	0.10

Table 1: Evaluation metrics for directional volatility predictions. (Using the traditional close-to-close volatility estimator and 4 different range-based estimators.)

### 3.2 Volatility Forecasting with Transfer Learning

Stock prices express common properties, which allows for building learning algorithms that can learn multiple assets’ price history. We aimed to study if a jointly trained neural network can produce better volatility forecasts than the individually trained models. (Here we defined volatility as a moving standard deviation of the returns.) We used a one-dimensional dilated causal convolutional neural network that was trained on the volatility history of hundreds of stocks, but not the stocks that we aimed to forecast. That is, the forecasting model did not know anything about the assets that it was applied to forecast. This jointly trained model was compared to individually trained convolutional neural networks and ARIMA models. Our proposed transfer learning approach produced clearly better results than the benchmark models, considering either value or direction forecasts. The results show that **jointly trained neural**

**networks can work well for volatility forecasting**, which allows for much better applications of deep learning in the field.

### 3.3 Inspecting the Stylized Facts of Volatility

The stylized facts claim that volatility is related to returns, volumes, and even to certain external variables. We tried to investigate if the claimed relationships exist. We used a long short-term memory neural network with multiple explanatory variables. The models were trained on bootstrap sampled subsets of the time series. Bootstrapping allowed us to produce more stable forecasts, to measure the uncertainty of the predictions, and to quantify feature importances. We found that **volatility and return are important predictors of future volatility**. Trading volume had less importance in our forecasting model.

### 3.4 Value-at-Risk Forecasting With Quantile Convolutional Neural Networks

We used a jointly trained one-dimensional dilated causal convolutional neural network to forecast Value-at-Risk. (Value-at-Risk is a quantile of the return distribution: it is a loss that is only exceeded with a predefined small probability.) We used the pinball loss function to forecast quantiles using the raw returns as input variables. We produced one-day Value-at-Risk forecasts for 100 US stocks with 3 different confidence levels. Several benchmark models were used: individually trained convolutional neural networks, linear quantile regressions, GARCH models, and constant quantile estimates. While various methods

produced fairly accurate exceedance rates, the proposed quantile convolutional neural network typically delivered lower Value-at-Risk estimates. The dynamic quantile test also showed that **the QCNN’s forecasts were superior to the baseline models.**

### 3.5 Mortality Forecasting with Recurrent Neural Networks

In a separate study, we analyzed the performance of the Lee-Carter mortality rate forecasting model. It is a very widely used and widely accepted method in the field. However, it was reported to show suboptimal performance for countries that have experienced some kind of mortality shock—for example, for post-socialist countries, such as Hungary. Previously, Baran et al. [2007] found that using a multi-factor variant of the Lee-Carter model, and omitting the pre-regime change observations lead to more reasonable forecasts. We found that now, having more data, **the original Lee-Carter model is becoming more applicable**, but excluding observations from before the regime change is still beneficial. We also used the Lee-Carter model as a benchmark in our subsequent study, where we’ve built a deep learning model for mortality forecasting.

We applied the jointly trained deep learning approach to mortality rate forecasting, as well. Since the recorded time series of mortality rates are short, and long-term forecasts are required, it is a challenging task. While the individual time series are short, there are multiple similar time series, and for this reason, even traditional approaches use multiple series for model training. The Lee-Carter model aims to find a general mortality

### 3.5 Mortality Forecasting with Recurrent Neural Networks 11

trend across different age groups. We proposed a recurrent neural network-based forecasting model that, similarly, learns from the mortality rates of different ages, but it can also be extended to learn from the mortality history of both sexes or different countries. We produced 10-year recursive forecasts for 35 countries, and compared the predictions of the Lee-Carter model and the neural networks using various regression metrics. The recurrent neural network expressed superior forecasting performance, especially when it was trained on all countries' data. **The proposed model outperformed the basic Lee-Carter model by a large margin.** Some extended Lee-Carter models produced more competitive, but still worse forecasts than most neural networks. The results show that, even though mortality rate datasets are small, complex deep learning models can produce valuable forecasts (Table 2).

metric	LC	LSTM Country	LSTM World	LSTM Coed
RMSE	0.0115	0.0076	0.0058	0.0055
MAE	0.0109	0.0069	0.0051	0.0047
MedAE	0.0108	0.0067	0.0049	0.0045
SMAPE	24.85	18.02	15.82	20.76
ME	0.0085	0.0027	0.0037	0.0026

Table 2: Averaged evaluation metrics for mortality predictions. (LC: Lee-Carter model; LSTM Country: LSTM model trained on one country; LSTM World: LSTM model trained on all countries; LSTM Coed: LSTM model trained on all countries and both sexes)

## 4 Conclusions

The aim of our research was to bridge the gap between deep learning and time series forecasting, and to prove the chosen methods with useful applications. We produced various financial forecasting studies using recurrent and convolutional neural networks. Deep learning-based forecasting is not a novelty, but it is not very common either, since there are some difficulties regarding, for example, the size of data or the interpretability of the models. We tried to show that these difficulties can be overcome, and we managed to deliver competitive (or, at least, promising) forecasts for various tasks and datasets. We hope that the models and methods that we used will be useful, and that we have managed to contribute to this interesting field of research.

## Scientific Work

- Petneházi, G., & Gáll, J. (2019). Exploring the predictability of range-based volatility estimators using recurrent neural networks. *Intelligent Systems in Accounting, Finance and Management*, 26(3), 109-116., <https://onlinelibrary.wiley.com/doi/full/10.1002/isaf.1455>.
- Petneházi, G., & Gáll, J. (2022). Evaluating the Lee-Carter model on Hungarian mortality data, *Acta Oeconomica*, accepted.
- Aradi, B., Petneházi, G., & Gáll, J. (2020). Volatility Forecasting with 1-dimensional CNNs via transfer learning. arXiv preprint arXiv:2009.05508., <https://arxiv.org/abs/2009.05508>.
- Petneházi, G. (2019). Quantile Convolutional Neural Networks for Value at Risk Forecasting. arXiv preprint arXiv:1908.07978., <https://arxiv.org/abs/1908.07978>.
- Petneházi, G., & Gáll, J. (2019). Mortality rate forecasting: can recurrent neural networks beat the Lee-Carter model?. arXiv preprint arXiv:1909.05501., <https://arxiv.org/abs/1909.05501>.
- Petneházi, G. (2019). Recurrent neural networks for time series forecasting. arXiv preprint arXiv:1901.00069., <https://arxiv.org/abs/1901.00069>.

## References

- Bernadett Aradi, Gábor Petneházi, and József Gáll. Volatility forecasting with 1-dimensional cnns via transfer learning. *arXiv preprint arXiv:2009.05508*, 2020.
- Sándor Baran, József Gáll, Márton Ispány, and Gyula Pap. Forecasting hungarian mortality rates using the Lee-Carter method. *Acta Oeconomica*, 57(1):21–34, 2007.
- Anastasia Borovykh, Sander Bohte, and Cornelis W Oosterlee. Conditional time series forecasting with convolutional neural networks. *arXiv preprint arXiv:1703.04691*, 2017.
- Yitian Chen, Yanfei Kang, Yixiong Chen, and Zizhuo Wang. Probabilistic forecasting with temporal convolutional neural network. *Neurocomputing*, 2020.
- Kyunghyun Cho, Bart Van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*, 2014.
- R Glen Donaldson and Mark Kamstra. Forecast combining with neural networks. *Journal of Forecasting*, 15(1):49–61, 1996.
- Christian L Dunis and Xuehuan Huang. Forecasting and trading currency volatility: An application of recurrent neural regression and model combination. *Journal of forecasting*, 21(5): 317–354, 2002.

- Robert Engle. Garch 101: The use of arch/garch models in applied econometrics. *Journal of economic perspectives*, 15(4):157–168, 2001.
- Rui Fu, Zuo Zhang, and Li Li. Using lstm and gru neural network methods for traffic flow prediction. In *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, pages 324–328. IEEE, 2016.
- Felix A Gers, Douglas Eck, and Jürgen Schmidhuber. Applying lstm to time series predictable through time-window approaches. In *Neural Nets WIRN Vietri-01*, pages 193–200. Springer, 2002.
- Tian Guo, Zhao Xu, Xin Yao, Haifeng Chen, Karl Aberer, and Koichi Funaya. Robust online time series prediction with recurrent neural networks. In *2016 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, pages 816–825. Ieee, 2016.
- Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, 1997.
- Kevin J Lang, Alex H Waibel, and Geoffrey E Hinton. A time-delay neural network architecture for isolated word recognition. *Neural networks*, 3(1):23–43, 1990.
- Ronald D Lee and Lawrence R Carter. Modeling and forecasting us mortality. *Journal of the American statistical association*, 87(419):659–671, 1992.

- Mary Malliaris and Linda Salchenberger. Using neural networks to forecast the s&p 100 implied volatility. *Neurocomputing*, 10(2):183–195, 1996.
- Aaron van den Oord, Sander Dieleman, Heiga Zen, Karen Simonyan, Oriol Vinyals, Alex Graves, Nal Kalchbrenner, Andrew Senior, and Koray Kavukcuoglu. Wavenet: A generative model for raw audio. *arXiv preprint arXiv:1609.03499*, 2016.
- Gábor Petneházi. Quantile convolutional neural networks for value at risk forecasting. *arXiv preprint arXiv:1908.07978*, 2019a.
- Gábor Petneházi. Recurrent neural networks for time series forecasting. *arXiv preprint arXiv:1901.00069*, 2019b.
- Gábor Petneházi and József Gáll. Exploring the predictability of range-based volatility estimators using recurrent neural networks. *Intelligent Systems in Accounting, Finance and Management*, 26(3):109–116, 2019a.
- Gábor Petneházi and József Gáll. Mortality rate forecasting: can recurrent neural networks beat the Lee-Carter model? *arXiv preprint arXiv:1909.05501*, 2019b.
- Gábor Petneházi and József Gáll. Evaluating the Lee-Carter model on hungarian mortality data. *Acta Oeconomica*, accepted.
- Ser-Huang Poon and Clive WJ Granger. Forecasting volatility in financial markets: A review. *Journal of economic literature*, 41(2):478–539, 2003.

- Yao Qin, Dongjin Song, Haifeng Chen, Wei Cheng, Guofei Jiang, and Garrison Cottrell. A dual-stage attention-based recurrent neural network for time series prediction. *arXiv preprint arXiv:1704.02971*, 2017.
- Ronald Richman and Mario V Wuthrich. A neural network extension of the Lee-Carter model to multiple populations. *Available at SSRN 3270877*, 2018.
- David Salinas, Valentin Flunkert, Jan Gasthaus, and Tim Januschowski. Deepar: Probabilistic forecasting with autoregressive recurrent networks. *International Journal of Forecasting*, 36(3):1181–1191, 2020.
- Paras Shah and Allon Guez. Mortality forecasting using neural networks and an application to cause-specific data for insurance purposes. *Journal of Forecasting*, 28(6):535–548, 2009.
- James W Taylor. A quantile regression neural network approach to estimating the conditional density of multiperiod returns. *Journal of Forecasting*, 19(4):299–311, 2000.
- Agnieszka Werpachowska. Forecasting the impact of state pension reforms in post-brexit england and wales using microsimulation and deep learning. *arXiv preprint arXiv:1802.09427*, 2018.
- Ruoxuan Xiong, Eric P Nichols, and Yuan Shen. Deep learning stock volatility with google domestic trends. *arXiv preprint arXiv:1512.04916*, 2015.

Xing Yan, Weizhong Zhang, Lin Ma, Wei Liu, and Qi Wu. Parsimonious quantile regression of financial asset tail dynamics via sequential learning. In *Advances in Neural Information Processing Systems*, pages 1575–1585, 2018.

Fisher Yu and Vladlen Koltun. Multi-scale context aggregation by dilated convolutions. *arXiv preprint arXiv:1511.07122*, 2015.



Registry number: DEENK/345/2021.PL  
Subject: PhD Publication List

Candidate: Gábor Petneházi  
Doctoral School: Doctoral School of Mathematical and Computational Sciences  
MTMT ID: 10069252

### List of publications related to the dissertation

#### Foreign language scientific articles in Hungarian journals (1)

1. **Petneházi, G.**, Gáll, J.: Evaluating the Lee-Carter model on Hungarian mortality data.  
*Acta Oecon. "Accepted by Publisher"* (-), 1-12, 2021. ISSN: 0001-6373.  
IF: 0.914 (2019)

#### Foreign language scientific articles in international journals (1)

2. **Petneházi, G.**, Gáll, J.: Exploring the predictability of range-based volatility estimators using recurrent neural networks.  
*Intell Sys Acc Fin Mgmt.* 26 (3), 109-116, 2019. ISSN: 1055-615X.  
DOI: <http://dx.doi.org/10.1002/isaf.1455>

**Total IF of journals (all publications): 0,914**

**Total IF of journals (publications related to the dissertation): 0,914**

The Candidate's publication data submitted to the iDEa Tudóstér have been validated by DEENK on the basis of the Journal Citation Report (Impact Factor) database.

03 June, 2021

