

# **Použitie umelej inteligencie pri predikovaní bankových kríz**

Using artificial intelligence to predict bank crises

Zuzana KOŠŤÁLOVÁ, Peter GERNÁT

## **Abstrakt**

Umelá inteligencia v súčasnosti zaznamenáva veľký boom, ktorý je hlavne podmienený rastúcim množstvom dát, tzv. Big Data. Techniky umelej inteligencie si našli široké uplatnenie v rôznych oblastiach. Tento článok predstavuje techniky umelej inteligencie, ktoré boli využité pri tvorbe systémov včasného varovania pre bankové krízy. Výhodou algoritmov umelej inteligencie je ich schopnosť pracovať s veľkým množstvom dát a zachytiť nelineárne vzťahy. Tieto schopnosti by mali reflektovať na dynamické a komplexné vzťahy vo finančnom systéme a prispieť tak k vylepšeniu modelov včasného varovania pre bankové krízy a spresniť ich out-of-sample prognózy.

## **Kľúčové slová**

Bankové krízy, umelá inteligencia, neparametrické metódy, systémy včasného varovania

## **Abstract**

In recent years, artificial intelligence has been experiencing a boom, mostly thanks to a rising amount of data, the so-called Big Data. The application of artificial intelligence techniques can be found in many fields. This paper presents artificial intelligence techniques which have been applied in construction of the early warning system for banking crisis. One of advantages of artificial intelligence is its ability to work with a lot of data and capture nonlinear relationships among variables. These abilities are supposed to take into account dynamic and complex relationships in the financial system and therefore contribute to improve early warning models for banking crisis and make more accurate out-of-sample forecasts.

## **Key words**

Banking crises, artificial intelligence, nonparametric methods, early warning systems

## **JEL classification**

C14, C40, C53, G01, F21

Vedecký časopis FINANČNÉ TRHY, Bratislava, Derivát 2018, ISSN 1336-5711, 3/2018

Článok bol spracovaný ako súčasť projektu VEGA č. 1/0693/17 – "Banková únia: systémový prístup k vyhodnoteniu príčin a dopadov zavedenia bankovej únie na bankový sektor SR a štátov Eurozóny" a KEGA č. 030EU-4/2017 – "Výskumom podporovaný rozvoj finančnej gramotnosti v podmienkach SR".

## 1. Úvod

Mnohé štúdie potvrdili, že bankové krízy prinášajú značné fiškálne náklady a zvyšujú verejný dlh. Podľa štúdie Medzinárodného menového fondu (2014) za obdobie rokov 1970 – 2011 medián nákladov na vládne intervencie tvoril 7% HDP [15]. Okrem fiškálnych nákladov majú bankové krízy negatívny dopad na ekonomický rast, obmedzujú efektívne využitie domácich úspor a vedenie monetárnej politiky. Bankové krízy nepredstavujú riziko len pre krajinu, v ktorej vznikli, ale predstavujú aj riziko nákazy do iných štátov. Značné finančné dopady bankových kríz a náklady na ich riešenie sú jedným z dôvodov o zvýšení záujmu o konštruovanie predikčných modelov pre bankové krízy, resp. systémov včasného varovania (early warning system) [8]. Systémy včasného varovania sú funkčné modely založené na indikátoroch, ktoré sú spájané s minulými krízami. Ich cieľom je upozorniť na potenciálne riziká, resp. upozorniť na potenciálnu blížiacu sa krízu. Predpokladom pri tvorbe týchto systémov je existencia kauzálneho vzťahu medzi krízami a indikátormi a možnosť identifikácie týchto ukazovateľov ex ante. Systémy včasného varovania z pohľadu inštitúcií bankového dohľadu predstavujú modely na zachytenie rôznych typov rizík v bankovom sektore.

Druhým dôvodom zvýšeného záujmu o systémy včasného varovania je fakt, že sa zatiaľ nepodarilo vytvoriť model včasného varovania, ktorý by bol stopercentne spoľahlivý pri predikovaní potenciálnych bankových kríz. Mnohé modely včasného varovania majú dobré výsledky pri in-sample predikcii, ale slabé výsledky z out-of-sample predikcie. Tento dôvod súvisí aj so samotným charakterom bankových kríz, ktoré sú zriedkavými udalosťami a ktoré v mnohých prípadoch mali rôzne príčiny a dopady. Z tohto dôvodu sa modely včasného varovania sústavne rozvíjali so zvyšujúcim sa počtom bankových kríz. Tieto modely včasného varovania sú často založené na rôznych definíciách bankovej krízy, vychádzajú z rôznych zdrojov bankových kríz, alebo používajú rôzne závislé premenné a metodológie.

Okrem využitia tradičných štatistických metód pri tvorbe systémov včasného varovania - signalizačnej metódy a logistickej regresie - v súčasnosti môžeme v literatúre identifikovať použitie novších metodológií. Jedná sa práve o metódy, ktoré sú založené na umelej

inteligencii (artificial intelligence) a ktoré by mali pomôcť pri predikcii kríz v zložitom a dynamickom prostredí ako je súčasný finančný systém.

Cieľom príspevku je informovanie o technikách umelej inteligencie pri modelovaní a prognózovaní bankových kríz. V ďalšej časti článku si predstavíme konkrétne empirické výskumy a ich výsledky prognózovania.

## **2. Metodológie na báze umelej inteligencie**

Okrem “tradičných” prístupov, môžeme v novších výskumoch vidieť snahu o predikovanie kríz pomocou metód založených na umelej inteligencii. Techniky umelej inteligencie by mali lepšie zachytiť komplexné a dynamické vzťahy vo finančnom systéme a zlepšiť schopnosť out-of-sample predikcie. Existuje mnoho metód v rámci umelej inteligencie.

V najnovších výskumoch sa využívajú nové algoritmy umelej inteligencie pri predikovaní krízy, ktoré využívajú techniku machine learningu (strojového učenia) založenú na data miningu (dolovaní dát). Tieto algoritmy testujú veľké množstvo dát a hľadajú vzťahy, schému, alebo modely, ktoré by dokázali predikovať daný jav. Techniky umelej inteligencie sa bežne využívajú v rôznych výskumných oblastiach ako napr. v informačných technológiach, medicínskom výskume, robotike, marketingu a vo finančníctve.

Medzi metodológiami na báze umelej inteligencie môžeme zaradiť nasledovné algoritmy:

- Klasifikačné a regresné stromy (CART - Classification and Regression Trees)
- Náhodný les (Random Forrest)
- CRAGGING
- Umelé neurónové siete (Artificial Neural Network)
- Systémy pracujúce na princípe fuzzy logiky (Fuzzy Logic)
- Metóda podporných vektorov (Support Vector Machines)
- K-najbližších susedov (k-nearest neighbors)
- Trait Recognition
- a ďalšie

## **3. Techniky umelej inteligencie v modeloch včasného varovania pre bankové krízy**

V tejto časti si predstavíme najčastejšie používané techniky umelej inteligencie, ktoré boli použité v empirických výskumoch a ktorých cieľom bolo predikovať bankové krízy. Konkrétne sa jedná o algoritmy:

- Klasifikačné a regresné stromy (CART - Classification and Regression Trees)

- Náhodný les (Random Forrest)
- CRAGGING
- Umelé neurónové siete (Artificial Neural Network)

### 3.1 Klasifikačné stromy a regresné stromy (Classification and Regression Trees)

Metóda klasifikačné stromy a regresné stromy (CART) je metóda machine learningu, ktorá odhaľuje nelineárne a interaktívne štruktúry v dátach. Táto metóda sa dá využiť na klasifikáciu dát, ale aj na regresnú analýzu. CART klasifikuje údaje na základe zadefinovaných pravidiel a člení ich do osobitých segmentov (stromových štruktúr). Rozhodovacie stromy budujú model v tvare stromu. Jeho začiatok je v koreňovom uzle, kde sú všetky dáta. Celý dataset sa potom rozdeľuje na rekurzívnom princípe na menšie a menšie pod-množiny alebo uzly dovtedy kým už nie je možné ďalej vytvoriť nový uzol. V rámci každého uzlu je jeden jednoduchý predikčný model. Finálny uzol zodpovedá modelu s najlepšou predikčnou schopnosťou [3].

CART metóda má niečo spoločné s logistickou regresiou aj so signálovou metódou. CART berie do úvahy diskrétny charakter bankovej krízy, ale poskytuje aj organizovaný výber indikátorov včasného varovania. Táto metóda dokáže určiť nielen hlavné krízové spúšťače a ich prahovú hodnotu prekročenia, ale aj určiť kombináciu podmienok, za ktorých sa typicky zvyšuje pravdepodobnosť krízy. CART berie do úvahy, že dopad nezávislých premenných na pravdepodobnosť bankovej krízy môže byť nelineárny. Zvýšenie alebo zníženie indikátora nemusí nutne viesť k bankovej kríze, kým daný indikátor neprekročí určitý prah, ktorý je identifikovaný touto technikou. Regresné stromy ponúkajú možnosť klásť otázky, pomocou ktorých sa dopracujú k výsledku, ktorý indikuje dôležité premenné v danom režime pri predikcii bankových kríz.

Vzhľadom na to, že CART je neparametrická metóda, nedokáže poskytnúť marginálny efekt jednotlivých vysvetľujúcich premenných. Na druhej strane CART dokáže poskytnúť informácie autoritám o indikátoroch, ktoré sú indikatívne a ktoré sú spoľahlivé [4, 10].

Tento prístup bol použitý v článku od Barrell, Davis, Karim a Liadze (2010). Autori okrem CART metódy, použili ďalšie dva prístupy - logistickú regresiu a signálovú metódu, aby porovnali vhodnosť využitia rovnakých systémov včasného varovania pre krajiny Latinskej Ameriky a Ázie za obdobie rokov 1980 – 2007. Jedine rast HDP bol významný indikátor pre všetky tri modely bez ohľadu na región. Autori zistili, že v každom type modelu boli iné predikčné indikátory a že predikčná schopnosť systémov včasného varovania je vyššia, ak sú

systemy diferencované pre regióny. V prípade metódy CART bol hlavný uzol, resp. hlavný predikčný indikátor vyjadrený pomerom vládneho prebytku k HDP pre ázijské krajiny a mierou znehodnotenia meny v prípade krajín Latinskej Ameriky [2].

Dutta Gupta a Cashin (2011) využili model binárneho klasifikačného stromu (Binary Classification Tree) pri analyzovaní bankových kríz. Na základe dát z 50-ich rozvíjajúcich sa ekonomík za obdobie rokov 1990 – 2005 autori identifikovali, že vysoká inflácia, kombinácia veľkého množstva vkladov denominovaných v dolároch s nominálnym znehodnotením alebo s nízkou likviditou banky a nízka ziskovosť bánk sú hlavné spúšťače bankovej krízy. Ich výsledky naznačujú, že komplexné a nelineárne interakcie medzi finančnými a makroekonomickými premennými majú vplyv na bankovú krízu. Práve vďaka technike klasifikačného stromu bolo možné odhaliť tieto nelineárne vzťahy, čo nie je možné dosiahnuť pri štandardnej regresnej analýze [4].

Joy et al. (2017) použili CART metodológiu na vzorke 36-ich rozvinutých krajín za obdobie rokov 1970 – 2010. Podľa autorov predikčná schopnosť rôznych indikátorov je odlišná pre rôzne časové horizonty. Kombinácia čistého úrokového spreadu (rozdiel medzi úrokovou sadzbou vkladu a úrokovou sadzbou na úver) s plochou alebo inverznou výnosovou krivkou sú dobrými indikátormi včasného varovania v krátkom časovom horizonte, jeden až dva roky pred vypuknutím bankovej krízy. Kľúčovým indikátorom pre predikovanie bankových kríz v rámci dlhšieho horizontu – dva až tri roky pred bankovou krízou je rast cien nehnuteľností. Domáce štrukturálne charakteristiky ako otvorenosť ekonomiky, štruktúra ekonomiky a finančný rozvoj ovplyvňujú náchylnosť krajiny na bankovú krízu. Zaujímavým výsledkom ich štúdie bolo zistenie, že indikátor credit-to-GDP gap stanovený Bazilejským výborom pre bankový dohľad ako kľúčový pri aktivácii proticyklického kapitálového vankúša, nevyšiel ako dôležitý indikátor pri predikcii bankových kríz [10].

### **3.2 Náhodný les (Random Forest)**

Náhodný les je technika machine learningu, ktorá je založená na metóde rozhodovacích stromov. Táto metóda dokáže pracovať s veľkým množstvom prediktorov a môže byť využitá pre klasifikačné úlohy a regresiu. Na rozdiel od CART, náhodný les funguje na princípe tvorby niekoľkých rozhodovacích stromov a súčasne odstraňuje nestabilitu, ktorá vzniká pri CART metóde. Je to metóda, ktorá dokáže odhadnúť chýbajúce údaje a udržiavať presnosť, aj keď chýbajú dáta. Nevýhodou tejto metódy je neprehľadnosť vzhľadom na to, že nie je možné

vidieť informácie jednotlivých stromov, pretože sú v rámci celého lesa. Preto sa niekedy náhodný les označuje ako “čierna skrinka” [11].

Podľa Alessi a Detken (2018) sa náhodný les ukazuje byť presným prediktorom, ktorý umožňuje hodnotiť dôležitosť premenných, čím poskytuje solídny základ pre výber relevantných indikátorov. Títo autori využili techniku náhodného lesa pri navrhovaní systému včasného varovania, ktorý identifikuje nadmerný úverový rast. Nadmerný rast úverov a s ním súvisiace hromadenie systémového rizika vo finančnom systéme by malo podľa autorov predchádzať bankovým krízam. Ich výsledky indikujú, že nasledovné premenné: credit-to-GDP gap, úverové indikátory, indikátory súvisiace s trhom nehnuteľností a globálny rast úverov majú dobrú predikčnú schopnosť [1].

### **3.3 CRAGGING**

Štatistický algoritmus CRAGGING je metóda skupinového machine learningu, ktorá sa využíva pri hodnotení dôležitosti premenných s hierarchickou štruktúrou. Umožňuje vybrať relevantné informácie o budúcich krízach a určiť prediktory kríz, ich interakcie a hodnoty prahu. Výsledkom je tiež stromová štruktúra, ktorá rozdeľuje dáta na menšie skupiny.

S cieľom vylepšiť metodológiu CART aplikovali Manasse et al. (2013) algoritmus CRAGGING pri tvorbe modelu včasného varovania pre bankové krízy pre rýchlo sa rozvíjajúce ekonomiky. Vzhľadom na to, že CART je designovaný na prierezové dáta, čo neumožňuje využiť informácie v panelových datasetoch, autori aplikovali CRAGGING, ktorý dokáže pracovať s panelovými dátami. Autori vytvorili dataset s 540-imi potenciálnymi vysvetľujúcimi premennými z rôznych sektorov pre 85 rýchlo sa rozvíjajúcich trhov za obdobie rokov 1980 - 2010. Následne aplikovali algoritmus náhodného lesa, aby vybrali významné premenné, čím sa znížil počet na 74 prediktorov. Ich výsledky naznačujú, že bankové krízy môžu byť predikované nasledovnými premennými: úroková sadzba na vklady, pomer zahraničných aktív k zahraničným záväzkom v bankovom sektore, domáci credit-to-GDP a pomer investícií k HDP. Autori zistili, že nie všetky bankové krízy sú rovnaké. Ich model identifikoval dva typy kríz. Prvý typ krízy je výsledkom kombinácie úverového boomu, predávaním domácich aktív, vysokými úrokovými sadzbami na vklady. Druhý typ krízy je výsledkom investovaného boomu, ktorý je financovaný zahraničným dlhom [14].

### **3.4 Umelé neurónové siete (Artificial Neural Networks)**

Metóda umelých neurónových sietí (ANN) je neparametrická štatistická metóda, ktorá obsahuje matematické a algoritmické elementy inšpirované fungovaním neurónov v ľudskom nervovom systéme. Základná terminológia umelých neurónových sietí vychádza z neurobiologickej terminológie. Umelé neurónové siete sa snažia napodobniť fungovanie ľudského mozgu. Matematický model neurónu pripomína svojou štruktúrou a činnosťou skutočný neurón nervovej sústavy. Neurón prijíma vstupy z iných neurónov, ale aj z okolitého sveta. Umelé neurónové siete prenášajú cez komunikačné kanály numerické informácie a spracovávajú ich v umelých neurónoch. Model ANN sa dokáže naučiť komplikované vzťahy medzi premennými a využiť tieto znalosti. Štruktúra umelých neurónových sietí sa mení podľa toho, ako prúdia interné a externé informácie cez siete počas fázy učenia. ANN využívajú aproximáciu nelineárnych funkcií na testovanie vzťahov medzi vysvetľujúcimi premennými [5]. ANN môžu byť využité pri regresii, pri rozpoznávaní a pri riešení klasifikačných problémov. Nevýhodou neurónových sietí je, že fungujú ako čierna skrinka, do ktorej prúdia vstupné informácie a následne dostaneme výsledky, pričom sa nevie ako presne neurónové siete prišli k danému výsledku [12].

Parametre v ANN modeli je potrebné odhadnúť predtým, ako sa siete využijú na predikciu. Neurónové siete môžu byť siete s dopredným šírením (feed-forward neural networks) alebo rekurentné siete (feedback/reccurent neural networks). V neurónových sieťach s dopredným šírením sa informácie šíria len jedným smerom po orientovaných synaptických prepojeniach, od predchádzajúcej vrstvy (vstupu) k najvyššej vrstve (výstupu). V rekurentných neurónových sieťach môžu neuróny prijímať inputy z iných neurónov z rôznych vrstiev v sieti [20]. Na rozdiel od signálovej metódy a logistickej regresie, umelé neurónové siete nie sú veľmi rozšírené v literatúre o systémoch včasného varovania pre finančné krízy. Zatiaľ čo umelé neurónové siete boli aplikované pri predikcii iných typov finančných kríz ako napr. pri predikcii menových kríz (napr. Nag a Mitra, 1999 [16]; Franck a Schmied, 2003 [7]; Sarlin and Marghescu, 2011 [19]), alebo suverénnych dlhových kríz (Fioramanti, 2008 [6]), metóda ANN sa začala objavovať v literatúre o bankových krízach nedávno (Ristolainen, 2015, 2018 [17, 18]; Holopainen a Sarlin, 2017 [9]).

Model ANN dokáže brať do úvahy nelineárny vzťah medzi pravdepodobnosťou bankovej krízy a indikátormi. Marginálne zvýšenie pravdepodobnosti bankovej krízy môže byť rôzne pri rôznych kombináciách indikátorov, alebo pri rôznych zvýšeníach jedného indikátora [13]. Ristolainen (2018) vytvoril systém včasného varovania, ktorý je založený na modeli dopredných viacvrstvových neurónových sietí. Viacvrstvové neurónové siete pozostávajú z

viac ako jednej vrstvy, resp. neuróny sú v sieti usporiadané do niekoľkých vrstiev. Na základe mesačných dát od januára 1970 do júna 2003 za 18 krajín testoval autor, či je možná out-of-sample predikcia za pomoci ANN modelu. Pomer domáceho úveru k HDP, pomer peňažného agregátu M2 k devízovým rezervám, reálny rast HDP, inflácia a cena ropy vyšli ako najdôležitejšie indikátory, ktoré majú vplyv pri klasifikovaní na predkrízové obdobie a “normálne” obdobie. Autor následne porovnával predikčnú schopnosť ANN model s modelom včasného varovania založeného na logistickej regresii za pomoci ROC (receiver operating characteristic)<sup>1</sup> kriviek. Autor zistil, že model založený na umelých neurónových sieťach lepšie identifikuje krízového obdobia. Tento výsledok naznačuje, že rozhodovacia hranica, ktorá klasifikuje, či pred-krízové obdobie a normálne obdobie patrí do priestoru krízového indikátora, je nelineárna [18].

#### 4. Záver

Vzhľadom na rôzne príčiny a dopady bankových kríz a meniace sa makroekonomické prostredie, systémy včasného varovania by nemali byť statické, ale mali by brať ohľad na meniace sa prostredie a podmienky, v ktorom fungujú bankové systémy. Systémy včasného varovania by mali vychádzať z nových dát a udalostí. Pri designovaní by sa mali tiež brať do úvahy meniaci sa charakter finančných trhov, nové finančné nástroje, prepojenie jednotlivých rizík a prenášanie rizík do iných bankových systémov. Najnovšie výskumné práce sa snažia reflektovať na komplexnosť vzťahov vo finančnom systéme a zlepšiť modely včasného varovania využitím nových ekonometrických techník a rozsiahlejších databáz. Využitie metodológií, ktoré sú založené na umelej inteligencii by mali prispieť k zlepšeniu predikčných modelov v zložitom a dynamickom prostredí. Empirické štúdiá ukázali, že techniky umelej inteligencie ako napr. klasifikačné a regresné stromy, náhodný les, CRAGGING a umelé neurónové siete majú lepšie out-of-sample predikčné výsledky ako tradičné metódy akými je signálna metóda a logit model. Ich výhodou je, že dokážu pracovať s veľkým množstvom dát a zachytiť nelineárne vzťahy. Na druhej strane aj tieto techniky majú svoje limity a nevýhody. Nevýhodou niektorých prístupov je ich ťažšia interpretácia. Niektoré výsledky algoritmov sa dajú intuitívne interpretovať ako napr. regresné stromy, ale

---

<sup>1</sup> ROC krivka zobrazuje všetky kombinácie pomeru správne identifikovaných kríz (tzv. skutočne pozitívnych prípadov) a pomeru nesprávne označených kríz (tzv. falošne pozitívnych prípadov) modelu pri rôznych hodnotách prahu pre pravdepodobnosť, kedy má byť pozorovanie klasifikované ako kríza, alebo bez-krízového obdobia. Pri porovnávaní ROC kriviek sa počíta plocha AUC pod krivkou (Area Under Curve). Čím je väčšia plocha AUC, tým je lepšia signalizačná schopnosť. Výhodou ROC krivky je, že sa nemusí pozerieť na preferencie politikov, alebo regulátorov.



niektoré algoritmy sú ťažšie interpretovateľné, aj keď efektívnosť predikcie je vysoká. CART metóda je transparentná, ale jej nevýhodou je, že nedokáže zahrnúť dodatočné pozorovania alebo prediktory. Nevýhodou techník náhodného lesa a umelých neurónových sietí je, že fungujú ako “čierne skrinky”. Preto je dôležité nájsť rovnováhu medzi ich interpretáciou a výkonom. Napriek nevýhodám, využitie algoritmov umelej inteligencie je perspektívne pri konštrukcii systémov včasného varovania pre bankové krízy.

### **Použitá literatúra**

- [1] ALESSI, L. – DETKEN, C. 2018. Identifying excessive credit growth and leverage. In *Journal of Financial Stability*, Vol. 35, April, str. 215-25. 2018.
- [2] BARRELL, R., - DAVIS, E., - KARIM, D., - LIADZE, I. 2010. Bank regulation, property prices and early warning systems for banking crises in OECD countries. In *Journal of Banking & Finance*, Vol 34, No 9, str. 2255-64. 2010.
- [3] BREIMAN, L. a kol.: *Classification and Regression trees*. London: Chapman & Hall, 1984. ISBN 9780412048418.
- [4] CASHIN, P. - DUTTAGUPTA, R. 2011. Anatomy of banking crises in developing and emerging market countries. In *Journal of International Money and Finance*, Vol. 30, No 2, str. 354-376. 2011.
- [5] DEMYANYK, Y., - HASAN, I. 2010. Financial crises and bank failures: A review of prediction methods. In *Omega*, Vol. 38, No 5. str. 315-324. 2010.
- [6] FIORAMANTI, M. 2008. Predicting sovereign debt crises using artificial neural networks: a comparative approach. In *Journal of Financial Stability*, Vol. 4, No 2, str. 149–164. 2008.
- [7] FRANCK, R., - SCHMIED, A. 2003. Predicting currency crisis contagion from East Asia to Russia and Brazil: An artificial neural network approach. *IMCB Working Paper*, No. 2. 2003. [online]. Dostupné na [http://econ.biu.ac.il/files/economics/shared/research/amcb/Publications/03.2\\_predicting\\_currency\\_crisis\\_contagion\\_from\\_east\\_asia\\_to\\_russia\\_and\\_brazil\\_-\\_an\\_artificial\\_neural\\_network\\_approach.pdf](http://econ.biu.ac.il/files/economics/shared/research/amcb/Publications/03.2_predicting_currency_crisis_contagion_from_east_asia_to_russia_and_brazil_-_an_artificial_neural_network_approach.pdf)
- [8] GOLDSTEIN, M. - KAMINSKY, G. - REINHART C. 2000. Assessing financial vulnerability, an early warning system for emerging markets: Introduction. *MPRA Paper*, No 13629. 2000. . [online]. Dostupné na [https://mpra.ub.uni-muenchen.de/13629/1/MPRA\\_paper\\_13629.pdf](https://mpra.ub.uni-muenchen.de/13629/1/MPRA_paper_13629.pdf)

- [9] HOLOPAINEN, M. – SARLIN, P. 2017. Toward robust early-warning models: A horse race, ensembles and model uncertainty. In *Quantitative Finance*, Vol. 17, No 12, str. 1933-1963. 2017.
- [10] JOY, M., - RUSNÁK, M., - ŠMÍDKOVÁ, K., - VAŠÍČEK, B. 2017. Banking and currency crises: Differential diagnostics for developed countries. In *International Journal of Finance & Economics*, Vol 22, No 1, str. 44-67. 2017.
- [11] KOMPRDOVÁ, K. a kol.: *Rozhodovací stromy a lesy*. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-785-7.
- [12] KVASNIČKA, V. a kol.: *Úvod do teórie neurónových sietí*. Bratislava: IRIS, 1997. ISBN 80-88778-30-1.
- [13] LO DUCA, M., - PELTONEN, T. 2013. Assessing systemic risks and predicting systemic events. In *Journal of Banking & Finance*, Vol. 37, No 7, str. 2183-2195. 2013.
- [14] MANASSE, P. - SAVONA, R. - VEZZOLI, M. 2013. Rules of Thumb for Banking Crises in Emerging Markets. *Quaderni DSE Working Paper*, No 872. 2013. [online]. Dostupné na <https://www.econstor.eu/bitstream/10419/159711/1/wp0872.pdf>
- [15] MEDZINÁRODNÝ MENOVÝ FOND. 2014. From Banking to Sovereign Stress - Implications For Public Debt. *IMF Policy Papers*. 2014. [online]. Dostupné na <https://www.imf.org/en/Publications/Policy-Papers/Issues/2016/12/31/From-Banking-to-Sovereign-Stress-Implications-For-Public-Debt-PP4940>>
- [16] NAG, A. – MITRA, A. 1999. Neural networks and early warning indicators of currency crisis. *Reserve Bank of India Occasional Papers*, Vol. 20, No2. str. 183–222. 1999.
- [17] RISTOLAINEN, K. 2015. Were the Scandinavian Banking Crises Predictable? A Neural Network Approach. *Aboa Centre for Economics*; 2015. [online]. Dostupné na <http://ace-economics.fi/kuvat/dp99.pdf>
- [18] RISTOLAINEN, K. 2018. Predicting Banking Crises with Artificial Neural Networks: The Role of Nonlinearity and Heterogeneity. In *The Scandinavian Journal of Economics*, Vol 120, No 1, str. 31-62. 2018.
- [19] SARLIN, P. - MARGHESCU, D. 2011. Visual predictions of currency crises using self-organizing maps. In *Intelligent Systems in Accounting, Finance and Management*, Vol 18, No 1. str. 15-38. 2011.
- [20] SINČÁK, P. – ANDREJKOVÁ, G. 2011. Neurónové siete Inžiniersky prístup (1. diel) [online]. Dostupné na <http://www.kuzo.szm.com/neuronky1.pdf>

**Kontaktné údaje**

Ing. Peter Gernát, Ing. Zuzana Košťálová

Katedra bankovníctva a medzinárodných financií

Národohospodárska fakulta

Ekonomická univerzita v Bratislave

Dolnozemska cesta 1

852 35 00 Bratislava

Slovenská republika

Email: [peter.gernat@euba.sk](mailto:peter.gernat@euba.sk), [zuzana.kostalova@euba.sk](mailto:zuzana.kostalova@euba.sk)