

# VYUŽITIE SKÓRINGOVÝCH MODELOV PRI PREDIKCII ÚPADKU EKONOMICKÝCH SUBJEKTOV V SLOVENSKEJ REPUBLIKE

Matúš Mihalovič\*

## Abstract

### Applicability of Scoring Models in Firms' Default Prediction. The Case of Slovakia

Bankruptcy prediction has long been regarded as a critical topic within the academic and banking community. To the best of our knowledge, no previous study in the Slovak Republic has attempted to develop a bankruptcy prediction model putting together statistical and artificial intelligence approaches performed on a such an amount of data. This paper seeks to fill this gap. Our aim is to develop a hybrid bankruptcy prediction model using a genetic algorithm in the process of training a neural network (GA-NN). The research data set comprises a balanced sample of both healthy and bankrupt firms operating in Slovakia in the period from 2014 to 2017. Financial information regarding a firm's financial situation are acquired from the Finstat database, which stores annual reports. For the purpose of comparing the classification accuracy of the proposed GA-NN model, two more models are constructed, namely BP-NN (back-propagation neural network model) as well as MDA (multiple discrimination model). The results gained by utilizing these models suggest the superiority of the developed GA-NN model to both BP-NN and MDA models in terms of prediction performance.

**Keywords:** bankruptcy prediction, genetic algorithms, hybrid classifier, neural networks, prediction performance, scoring model, GA-NN model, default, decision trees

**JEL Classification:** C450, C530, G320, G330, M210

## Úvod

V oblasti hodnotenia a predikcie finančnej situácie podniku bolo doteraz vytvorených množstvo predikčných modelov a v poslednom období sme svedkami mnohých trendov, ktorých význam sa v ekonomike zintenzívnuje. Hlavnými hybnými silami stimulujúcimi vývoj predikčných modelov boli: (1) prijatie súboru regulačných pravidiel vydaných Bazilejským výborom pre bankový dohľad v roku 2004, známych ako Basel II, ktoré nastavili nové podmienky pre výšku kapitálových a rizikových požiadaviek pre bankový sektor; (2) vypuknutie globálnej finančnej krízy v roku 2008, ktorá sa prejavila úpadkom viacerých podnikov a destabilizáciou jednotlivých ekonomík.

Je dôležité vyhnúť sa izolovanému pohľadu na dôsledky úpadku podniku. Zieba a kol. (2016) v tomto smere upozorňujú, že finančná situácia podnikov sa netýka len samotného podniku, ale ovplyvňuje aj ekonomiku ako celok. Práve preto vysoké spoľočenské a ekonomicke náklady ako dôsledky úpadku podnikov prilákali záujem vo výskumnej oblasti s cieľom detailnejšieho pochopenia príčin úpadku.

\* Matúš Mihalovič (matus.mihalovic@gmail.com), Ekonomická univerzita Bratislava, Podnikovohospodárska fakulta Košice.

Doteraz boli vytvorené viaceré predikčné modely vytvorené na vzorke zahraničných podnikov a v odlišnom období, čo znemožňuje ich aplikovateľnosť na Slovensku, a tak sa vytvára priestor na výskum v tejto oblasti. V oblasti skúmania predikcie úpadkov na Slovensku boli prvé náznaky zaznamenané len v poslednom období. Fidrmuc a Hainz (2010) zistili na vzorke slovenských malých a stredných podnikov využitím probit modelu, že ukazovatele *rentability* a *likvidity* sú dôležitým determinantom ich úpadku. Delina a Packová (2013) vytvorili regresný model a na základe porovnania s troma zahraničnými modelmi (Altmanov model, Beermanov model, český IN05 model) potvrdili vyššiu presnosť navrhnutého modelu. Ich zistenia potvrdili tézu o nevhodnosti aplikácie zahraničných modelov v podmienkach slovenskej ekonomiky. Gavurová a kol. (2017) na vzorke 700 slovenských podnikov došli k záveru, že české modely IN01 a IN05 boli presnejšie pri prognózovaní úpadku ako zahraničné modely Altman (1984) a Ohlson (1980). Kováčová a Klieštik (2017) hodnotili na vzorke slovenských podnikov výkonnosť dvoch modelov, pričom ich výsledky naznačujú, že využitie logit modelu prináša presnejšie výsledky ako probit modelu.

Účelom predkladaného príspevku je vytvorenie hybridného predikčného modelu finančnej situácie podnikov na vzorke slovenských podnikov, využívajúc neurónové siete a genetické algoritmy, a prispieť tak v oblasti predikcie finančnej situácie podnikov v Slovenskej republike na vzorke údajov z rokov 2014–2017. Prínosom empirickej štúdie by malo byť takisto vyplnenie medzery v aplikácii predikčného modelu finančnej situácie na vzorke slovenských podnikov, ktorý pri svojej tvorbe využíva hybridný prístup zapojením prostriedkov umelej inteligencie a evolučných predikčných prístupov.

Prvá kapitola predstavuje rešerš literatúry a vývojové tendencie využívaných predikčných modelov úpadku z hľadiska aplikovaných metód. Druhá kapitola vymedzuje ciele príspevku, objasňuje metodologický aparát využitý pri budovaní navrhovaného hybridného predikčného modelu a napokon tretia kapitola rekapituuluje dosiahnuté výsledky empirického výskumu.

## 1. Prehľad literatúry a predikčných modelov úpadku

Kedže štúdia pracuje so štatistickými, ako aj inteligenčnými prístupmi, tento typ úlohy je známy ako klasifikácia pre štatistické metódy a učenie s učiteľom pre prístupy využívajúce umelú inteligenciu. Z formálneho hľadiska môžeme klasifikačný problém vnímať nasledujúcim spôsobom: predpokladáme, že máme databázu s  $n$  podnikmi  $D = \{(x_1, y_1), \dots, (x_n, y_n)\}$ , v ktorej každý podnik  $x_i = (x_{i1}, x_{i2}, \dots, x_{iM})$  je charakterizovaný  $M$  premennými definovanými v priestore vstupných premenných  $X^M$ , pričom  $y_i \in \{zdravý podnik, podnik v úpadku\}$ . Potom klasifikátor (predikčný model) môžeme definovať ako funkciu zobrazenia  $f : X^M \rightarrow \{zdravý podnik, podnik v úpadku\}$  ktorý prognózuje hodnotu  $y$  pre jednotlivé podniky  $x$ , pričom platí  $f(x) = y$ .

Najvýznamnejším a najrozšírenejším užívateľom predikčných modelov úpadku sú nepochybne finančné inštitúcie, najmä komerčné banky, ktorých hlavnou motiváciou je vytvárať predikčné modely kreditného rizika vychádzajúce z Bazilejských pravidiel Basel II (2004) a Basel III (2010). Tie im ponúkajú možnosť vytvárať vlastné interné ratingy hodnotenia

klientov na základe tzv. IRB (internal rating-based) prístupu, ktoré majú zabrániť nedokonalostiam subjektívneho expertného hodnotenia kreditného rizika žiadateľov o úver.

V súčasnosti môžeme pozorovať viaceré tendencie týkajúce sa aplikácie predikčných modelov, pričom Sun a kol. (2014) osobitne poukazujú na tri vývojové tendencie: (1) prechod od jednorozmernej analýzy premenných k viacrozmernej predikcii; (2) posun od klasických štatistických metód k metódam strojového učenia založených na umelej inteligencii a (3) intenzívnejšie zapájanie hybridných a ensemble klasifikátorov.

Štatistické metódy zahŕňajú jednorozmernú analýzu finančných ukazovateľov, viacrozmernú diskriminačnú analýzu (MDA) a logistickú regresiu (logit). Priekopníkom vo využití viacrozmernej analýzy pri predikcii úpadku bol Altman (1968), ktorý vytvoril na základe viacrozmernej diskriminačnej analýzy známy Z-score model. V rámci štatistických metód bola využitá aj logistická regresia (Ohlson 1980), faktorová analýza (Lo, 1986).

V deväťdesiatych rokoch minulého storočia sa začali presadzovať najmä prístupy spojené s výpočtovou inteligenciou, ktoré sa stali v tomto období prevládajúcimi metódami. Prevládajúcim prístupom sa stali umelé neurónové siete, ktoré prvýkrát využili na účely predikciu úpadku.

Odom a Sharda (1990), pričom potvrdili superioritu oproti MDA modelu. Spomedzi vysokého počtu štúdií využívajúcich neurónové siete v predikčných modeloch uvádzame niektoré nedávne relevantné štúdie (Olson a kol. 2012; Fedorova a kol., 2013; Zieba a kol., 2016; Liang a kol., 2016), ktoré využívajú viacrozmerný perceptron (MLP), sieť radiálne bázických funkcií (RBF), učenie vektorovou kvantifikáciou (LVQ) a samoorganizujúce mapy (SOM) ako najčastejšie architektúry neurónových sieti. Okrem neurónových sieti boli využité aj ďalšie metódy, ako napríklad rozhodovacie stromy (Li a kol. 2010); teória podporných vektorov (SVM) (Shin a kol. 2005).

V priebehu posledných desaťročí je cieľný zvyšujúci sa záujem v oblasti biologicky a prírodou inšpirovaných optimalizačných metód, založené na Darwinových princípoch prirodzeného výberu a evolúcie. Marqués a kol. (2013) v tejto súvislosti naznačujú, že metódy evolučných výpočtov majú schopnosť extrahovať znalosti aj z nepresných a neúplných dát.

Genetické algoritmy (GA) sú inovatívnym prístupom v oblasti umelej inteligencie schopným riešiť komplexné problémy a podľa štúdie Gordini (2014) poskytujú viaceru výhodu oproti iným metódam, konkrétnie (1) GA sú adaptívne algoritmy schopné neustálej inovácie; (2) GA postačuje informácia o funkcií zdatnosti (fitness function); (3) GA sú užitočné pri hľadaní globálneho optimá výrazne nelineárnych a nekonvexných funkcií bez toho aby uviazali v lokálnom minime.

Jedným z prvých pokusov využitia genetických algoritmov pri predikcii úpadku bola štúdia autorov Backa a kol. (1996), ktorí porovnávali MDA, logit a GA a najlepšie výsledky dosiahli pri využití GA modelu. Shin a Lee (2002) preukázali, že GA model je užitočný a perspektívny predikčným modelom úpadku. Podobné výsledky vo svojej štúdií dosiahli aj Kim a Han (2003).

Uspokojivé výsledky dosiahla takisto štúdia Finlay (2009), ktorý porovnal výkonnosť logit modelu a klasického regresného lineárneho modelu s GA modelom. Gordini (2014) využil GA pri vytvorení predikčných klasifikačných pravidiel pre malé a stredné

podniky v Taliansku a s týmto prístupom prekonal výsledky logit a SVM klasifikátorov. Podobný prístup použili aj Gorzaczany a Rudzinski (2016), ktorí navrhli automatické vytvorenie klasifikátora na základe tzv. fuzzy pravidiel, pričom využili viacúčelový evo-lučný optimalizačný algoritmus.

Mnohé nedávne štúdie v oblasti predikcie úpadku naznačujú zvýšenie aplikácií vyu-žiteľnosti hybridných techník (Marqués a kol. 2013; Sun a kol. 2014). Min a kol. (2006) navrhli hybridný model kombinujúci GA a SVM a na účely zistenia efektívnosti modelu porovnali jeho výsledky s troma ďalšími modelmi: logit, NN a samostatný SVM. Ich výsledky naznačujú, že predikčná schopnosť modelu sa zapojením genetických algoritmov zvýšila. Oreski a Oreski (2014) využili kombináciu GA a NN na výber premenných s následnou tvorbou modelu. Acosta-Gonzalez a Fernandez-Rodriguez (2014) využili genetické algoritmy na výber finančných ukazovateľov využitých v logit modeli.

## 2. Metodológia a údaje

Štruktúra navrhovaného modelu GA-NN má hybridný charakter, čo v tomto kontexte znamená, že pri tvorbe modelu budú využité genetické algoritmy ako spôsob výberu pre-menných trénujúcich umelé neurónové siete. V tejto štúdií budú využité dve klasifikačné metódy, konkrétnie viacrozmerná diskriminačná analýza (MDA) a neurónové siete (NN). V rámci neurónových sietí budú využité dva rôzne algoritmy učenia siete Backpropaga-tion (BP) a genetické algoritmy (GA). Celkovo tak budú na účely hodnotenia predikčnej presnosti využité tri predikčné modely: MDA, BP-NN a GA-NN.

### 2.1 Predikčné metódy využité pri modelovaní

Kreditný skóring definujú Zhao a kol. (2015) ako súbor modelov rozhodovania, ktoré napomáhajú veriteľom posúdiť, či by mala byť žiadosť o úver schválená, alebo odmiet-nutá. Existujú dva druhy kreditného skóringu, a to tradičné a automatické. V porovnaní s tradičným skóringom, ktorý je predmetom výpočtu kreditných manažérov bájk, auto-matický skóring má viacero výhod: šetrí náklady a čas pri hodnotení nových žiadostí, je konzistentný a objektívny. Keďže presnosť skóringu môže výrazne ovplyvniť záujmy finančných inštitúcií, výskum v tejto oblasti sa snaží vylepšovať a zdokonaľovať miery presnosti vhodnou tvorbou predikčných modelov.

*Diskriminačná analýza* predstavuje podľa Hair a kol. (2014) klasifikačný problém, pri ktorom sú vopred známe dve alebo viacero skupín, pričom jednotlivé pozorovania sa klasifikujú do jednej z týchto skupín na základe nameraných hodnôt. Dá sa povedať, že lineárna diskriminačná analýza predstavuje metódu redukcie rozmernosti a jej hlavným cieľom je premietnuť dátu do priestoru s nižšou rozmernosťou vyznačujúcou sa vyššou separabilitou medzi skupinami.

Základnú štruktúru *neurónových sietí* tvorí orientovaný graf pozostávajúci z vrcho-lov (neurónov), sú usporiadane vo vrstvách a sú prepojené a hranami (synapsami) (Du a Swamy, 2014). Vstupná vrstva pozostáva zo všetkých vstupných premenných v oddelených neurónoch a výstupná vrstva pozostáva zo závislých premenných. Gunther a Frisch (2010) približujú funkciu najjednoduchšieho viacvrstvového perceptronu (MLP):

$$o(\mathbf{x}) = f\left(w_0 + \sum_{i=1}^n w_i x_i\right) = f\left(w_0 + \mathbf{w}^T \mathbf{x}\right), \quad (1)$$

kde  $w_0$  označuje konštantu,  $\mathbf{w} = (w_1, \dots, w_n)$  je vektor obsahujúci všetky synaptické váhy bez konštanty a  $\mathbf{x} = (x_1, \dots, x_n)$  je vektor všetkých vstupných premenných. S cieľom zvýšenia flexibility modelovania, môžu byť pripojené aj skryté vrstvy. Funkciu MLP so skrytou vrstvou pozostávajúca z  $J$  skrytých neurónov vypočítame ako:

$$\begin{aligned} o(\mathbf{x}) &= f\left(w_0 + \sum_{j=1}^J w_j \cdot f\left(w_{0j} + \sum_{i=1}^n w_{ij} x_i\right)\right) = \\ &= f\left(w_0 + \sum_{j=1}^J w_j \cdot f\left(w_{0j} + \sum_{i=1}^n \mathbf{w}_j^T \mathbf{x}\right)\right), \end{aligned} \quad (2)$$

kde  $w_0$  označuje konštantu výstupného neurónu a  $w_{0j}$  konštantu  $j$ -tého skrytého neurónu,  $w_j$  znamená synaptickú váhu prislúchajúcu synapsii začínajúcej na  $j$ -tom skrytom neuróne a vedúcej k výstupnému neurónu a  $\mathbf{w}_j = (w_1, \dots, w_n)$  je vektor všetkých synaptických váh synapsí vedúcich k  $j$ - temu skrytému neurónu.

Všetky skryté a výstupné neuróny počítajú výstup

$$f(g(z_0, z_1, \dots, z_k)) = f(g(\mathbf{z})) \quad (3)$$

z výstupov všetkých predchádzajúcich neurónov  $z_0, z_1, \dots, z_k$ , kde integračná funkcia  $g$  a aktivačná funkcia  $f$  sú:

$$g: R^{k+1} \rightarrow R \quad (4)$$

$$f: R \rightarrow R. \quad (5)$$

Integračnú funkciu môžeme definovať ako:

$$g(\mathbf{z}) = w_0 z_0 + \sum_{i=1}^k w_i z_i = w_0 + \mathbf{w}^T \mathbf{z}. \quad (6)$$

Ako aktivačná funkcia bola využitá logistická sigmoidná funkcia vzhľadom na binárny charakter našich výstupných premenných, keďže táto funkcia zobrazuje výstupy každého neurónu v intervale  $[0,1]$

$$f(u) = \frac{1}{1+e^{-u}} + \varepsilon_i. \quad (7)$$

Neurónová sieť vypočíta výstup  $o(x)$  pre dané vstupy  $\mathbf{x}$  a váhy a algoritmus učenia vypočíta chybovú funkciu. Pri modelovaní siete bola využitá suma štvorcov odchýlok (SSE), ktorá udáva rozdiel medzi predikovanými a pozorovanými výstupmi, kde  $l = 1, \dots, L$  predstavujú dané dvojice vstup-výstup a  $h = 1, \dots, H$  sú výstupné uzly.

$$E = \frac{1}{2} \sum_{l=1}^L \sum_{h=1}^H (o_{lh} - y_{lh})^2. \quad (8)$$

Pri objasnení postupu práce *genetických algoritmov* vychádzame z procedúry navrhnutej v publikácii Haupta a Haupta (2004). Inicializačná fáza genetických algoritmov začína vytvorením jedincov. Celý navrhnutý proces priradovania hodnoty fitness, selekcie, rekombinácie a mutácie je opakovaný dovtedy, kým nie je dosiahnuté kritérium zastavenia. Pokial sa táto úroveň nedosiahne, model začína celý proces odznova podľa nastavenej úrovne počtu generácií. Predikčný model s najmenšou chybou výberu spomedzi všetkých aplikovaných kombinácií je vybraný ako reprezentatívny tréningový model, ktorého výsledky, presnosť a výkonnosť bude následne otestovaná na testovacej množine dát.

## 2.2 Výber vzorky a použité údaje

### Výber vzorky

Pri tvorbe vzorky bol využitý stratifikovaný výber, ktorý v oblasti predikcie úpadku podnikov ponecháva všetky podniky v úpadku, ktoré majú dostupné údaje, vo vzorke, zatiaľ čo vyberá iba časť zdravých podnikov z celkovej populácie tak, aby bol zabezpečený rovnaký počet zdravých podnikov a podnikov v úpadku vo vzorke. Ako uvádzajú Tian a kol. (2015), využíva sa pri tom párovanie vzoriek, pri ktorých ako kritéria výberu zdravých podnikov boli využité veľkosť podniku a odvetvie, v ktorom pôsobí.

Pri výbere podnikov v úpadku bola využitá právna definícia úpadku podniku podľa zákona č. 7/2005 Z. z. o konkurze a reštrukturalizácii. Podnik bol zaradený do vzorky, ak bol na jeho majetok vyhlásený konkúr alebo bola povolená reštrukturalizácia. Účtovné závierky boli získané z databázy podnikových informácií Finstat. Ak napríklad voči podniku bolo začaté konkúrzné konanie v roku 2016, údaje o ňom boli čerpané z účtovnej závierky za rok 2015.

S cieľom kompenzácie nesymetrického rozdelenia podnikov vo vzorke boli vytvorené dve podvzorky podnikov (podniky v úpadku a zdravé podniky) rovnakej veľkosti. Keďže podľa vopred definovaných kritérií bolo do vzorky zaradených 640 podnikov v úpadku, vzorka bola následne doplnená o 640 zdravých podnikov v súlade s párovaním vzoriek, čím celková vzorka tvorí finálny súbor 1 280 podnikov.

### Výber premenných

Cieľom procesu výberu premenných je vyfiltrovať nereprezentatívne premenné s nízkou, rovnakou alebo žiadnou prediktívnu informáciou z daného súboru dát. Pri výbere počiatocného súboru premenných modelu GA-NN sme vychádzali z finančných ukazovateľov, ktoré boli využité v doterajších štúdiách pri tvorbe predikčných modelov. V prvej fáze redukcie premenných boli premenné predmetom skúmania deskriptívnej štatistiky, testovania zhody rozdelenia premenných s teoretickým normálnym rozdelením (Kolmogorov-Smirnovov test), zhodnotenia štatisticky významných rozdielov využitím Mannova-Whitneyova U testu a korelačnej analýzy s cieľom vyhnúť sa problémom spôsobených kolinearitou. Druhá fáza redukcie redundantných premenných bola realizovaná prostredníctvom stochastickej optimalizačnej metódy genetické algoritmy.

## Hodnotenie výkonnosti modelov

Na hodnotenie výkonnosti modelov bolo využitých päť hodnotiacich kritérií, ktorých hodnoty je možné získať výpočtom z tabuľky 1.

**Tabuľka 1 | Kontingenčná tabuľka**

		Skutočný stav	
		B (podnik v úpadku)	NB (zdravý podnik)
Predikcia	B (podnik v úpadku)	TP (skutočne pozitívny)	FP (falošne pozitívny)
	NB (zdravý podnik)	FN (falošne negatívny)	TN (skutočne negatívny)

Zdroj: vlastné spracovanie

Z kontingenčnej tabuľky vychádza výpočet jednotlivých hodnotiacich kritérií, ktorých bližší popis je uvedený v publikácii Ramachandran a Tsokose (2009).

*Chyba prvého druhu* pri predikcii nastáva vtedy, ak model nesprávne klasifikuje podnik v úpadku ako zdravý podnik, naopak *Chyba druhého druhu* nastáva v prípade, ak model nesprávne klasifikuje zdravý podnik ako podnik v úpadku. Ak uvažujeme o finančných inštitúciách ako o užívateľoch predikčného modelu, *Chyba prvého druhu* je pre nich závažnejšia ako *Chyba druhého druhu*, keďže poskytnú prostriedky aj podnikom, ktoré majú veľkú pravdepodobnosť úpadku. V prípade, že neposkytnú prostriedky zdravému podniku, tak pre nich strata predstavuje len náklady stratených príležitostí.

Ďalším hodnotiacim kritériom je *Presnosť predikcie*, ktorý hodnotí celkovú výkonusť modelu, teda podiel všetkých podnikov, ktoré model dokázal správne klasifikovať voči všetkým podnikom vo vzorke. Pre výpočet hodnotiaceho kritéria *G-priemer* je potrebné najprv vypočítať senzitivitu a špecifiku. Kým senzitivita v tomto prípade vyjadruje, aký podiel podnikov v úpadku dokáže model správne klasifikovať z celkového počtu podnikov v úpadku vo vzorke, špecifita podáva informáciu o podiele zdravých podnikov, ktoré model dokázal správne označiť za zdravé (Corder a Freeman, 2014). Ukazovateľ *G-priemer* potom vypočítame ako:

$$g - priemer = \sqrt{\text{špecifita} * \text{senzitivita}} .$$

Posledným nástrojom hodnotenia presnosti predikcie modelov je *F-ukazovateľ*, ktorý predstavuje harmonický priemer senzitivity a špecificity.

### 3. Výsledky empirického výskumu

Obdobia skúmania všetkých troch modelov sú identické (2014–2017), pričom odlišný je spôsob výberu premenných. Pri modeli MDA bola na výber premenných použitá jednorozmerná analýza vo forme *t-testu*, pričom z počiatočného súboru 18 premenných bolo vybraných päť premenných s najvyššími rozdielmi strednej hodnoty medzi zdravými podnikmi a podnikmi v úpadku, ktoré boli následne využité aj na trénovanie modelu BP-NN.

### 3.1 Výsledky modelu MDA

Pri tvorbe modelu MDA boli využité premenné získané výberom detailnejšie opísaným v príspevku Mihalovič (2015).

**Tabuľka 2 | Dosiahnuté výsledky modelu MDA**

Premenná				Wilk's lambda	F-štatistika	p-hodnota
<b>Čistý zisk/Celkové aktíva</b>				0,9689	7,5084	0,007*
<b>Obežný majetok/Krátkodobé záväzky</b>				0,9463	13,2554	0,000*
<b>Krátkodobé záväzky/Celkové aktíva</b>				0,9766	5,5977	0,019*
<b>Pracovný kapitál/Celkové aktíva</b>				0,9868	3,1001	0,079
<b>Obežný majetok/Celkové aktíva</b>				0,9990	0,2275	0,634
Funkcia	Vlastné číslo	Kanonické R <sup>2</sup>	Wilk's lambda	Chí-kvadrát	Stupne voľnosti	p-hodnota
1	0,10007	0,0909	0,372	20,181	4	0,000*
<b>Štruktúrovaná matica</b>						
<b>Nezávislá premenná</b>				<b>Diskriminačná korelácia</b>		
<b>Čistý zisk/celkové aktíva</b>				-0,5846		
<b>Obežný majetok/krátkodobé záväzky</b>				-0,7677		
<b>Krátkodobé záväzky/celkové aktíva</b>				0,5068		
<b>Pracovný kapitál/celkové aktíva</b>				-0,3791		
<b>Obežný majetok/celkové aktíva</b>				-0,1033		

Zdroj: vlastné spracovanie

Výsledky Wilk's lambda testu (tabuľka 2) naznačujú, že hodnoty kombinácie nezávislých premenných tvoriace model MDA nie sú pre dve skupiny podnikov rovnaké (p-hodnota 0,000). Inými slovami môžeme konštatovať, že kanonická diskriminačná funkcia vytvorenej vzorky dokáže kvalitne rozlišovať medzi dvoma heterogénnymi skupinami podnikov. Takisto môžeme poznamenať, že 37,2 % variability v diskriminačnom skóre rozdielnych skupín nedokáže model vysvetliť. Najvyšší stupeň závislosti v rámci ukazovateľov bol zaznamenaný pri premennej *Obežný majetok/Krátkodobé záväzky v negatívnom smere*. To znamená, že čím nižšia hodnota tohto ukazovateľa, tým vyššia pravdepodobnosť úpadku podniku.

**Tabuľka 3 | Kontingenčná tabuľka výsledkov modelu MDA**

Tréningová vzorka (n = 1 024)		Skutočný stav	
		B (podnik v úpadku)	NB (zdravý podnik)
Predikcia	B (podnik v úpadku)	304	165
	NB (zdravý podnik)	226	325
Testovacia vzorka (n = 256)		Skutočný stav	
		B (podnik v úpadku)	NB (zdravý podnik)
Predikcia	B (podnik v úpadku)	56	24
	NB (zdravý podnik)	67	109

Zdroj: vlastné spracovanie

Model MDA (tabuľka 3) dokázal správne klasifikovať 629 podnikov z tréningovej vzorky 1 024 podnikov. Na testovacej vzorke správne klasifikoval 165 podnikov.

### 3.2 Výsledky modelu BP-NN

Výsledkom trénovania neurónovej siete je určenie výstupnej premennej pre každý podnik v tréningovej vzorke, ktorý je následne porovnávaný so skutočnou hodnotou výstupnej premennej. Porovnávaním týchto hodnôt dokážeme určiť, akých chýb sa navrhnutý model dopúšťa a akú výkonnosť má daný model pri predikcii na testovacej vzorke podnikov. Výsledky sme zaznamenali v tabuľke 4.

**Tabuľka 4 | Kontingenčná tabuľka výsledkov modelu BP-NN**

Tréningová vzorka (n = 1 024)		Skutočný stav	
		B (podnik v úpadku)	NB (zdravý podnik)
Predikcia	B (podnik v úpadku)	447	66
	NB (zdravý podnik)	127	384
Testovacia vzorka (n = 256)		Skutočný stav	
		B (podnik v úpadku)	NB (zdravý podnik)
Predikcia	B (podnik v úpadku)	101	12
	NB (zdravý podnik)	27	116

Zdroj: vlastné spracovanie

Model BP-NN správne klasifikoval na tréningovej vzorke 831 podnikov z celkového počtu 1 024, pričom presnejší bol pri hodnotení finančnej situácie podnikov

v úpadku (447) ako pri klasifikácii zdravých podnikov (384). Tento model sa dopustil výraznejších chýb v situácii, kedy označil zdravé podniky ako podniky v úpadku (127), kým v opačnom prípade model chybne klasifikoval podnik upadajúci ako podnik zdravý v celkom 66 prípadoch. V prípade testovacej vzorky model dokázal klasifikovať správne 217 z 256 podnikov, pričom rovnako ako v prípade tréningovej vzorky viac chýb bolo zaznamenaných v prípadoch, kedy bol zdravý podnik označený ako podnik v úpadku (27 oproti 12 prípadom).

### 3.3 Výsledky modelu GA-NN

Hybridný model GA-NN využíva 12 vstupných premenných, ktoré sú výsledkom dvojfázovej redukcie počiatočného súboru 58 premenných. Ešte pred samotným procesom tréningu bola vzorka 1 280 podnikov rozdelená na tréningovú a testovaciu množinu v pomere 80:20 v prospech tréningovej množiny.<sup>1</sup>

Prvotným krokom pri tvorbe GA-NN modelu bolo vytvorenie populácie 50 binárnych reťazcov (chromozómov) so šiestimi premennými, z ktorých každý tvorí jedinečnú štruktúru neurónovej siete. Počet generácií bol nastavený na 70, vychádzajúc z výsledkov predchádzajúcich experimentov<sup>2</sup>, podľa ktorých priemerné fitness v populácii zvyčajne konverguje k stabilnej hladine po 60 generáciách. Zhrnutie nastavenia parametrov pred spustením GA-NN modelu viz tabuľka 5.

Finálny hybridný model GA-NN pozostáva zo šiestich vstupných premenných, ktoré algoritmus vybral ako najlepšiu kombináciu s najvyššou predikčnou schopnosťou. Najvyššiu predikčnú schopnosť mal model s týmito 6 premennými: *Pridaná hodnota/Tržby, EBIT/Celkové aktíva, Pracovný kapitál/Celkové aktíva, Celkové záväzky/EBITDA, Neobežný majetok/Celkové aktíva, Likvidita 3. stupňa*. Následne boli na základe vybraných vstupných premenných údaje otestované na testovacej vzorke.

Evolučný proces genetických algoritmov sa so zvyšujúcim počtom generácií zdokonaloval, čoho výsledkom je zvyšujúca sa hodnota fitness, reprezentovaná ukazovateľom Predikčná presnosť. Výkonnosť modelu GA-NN bola rovnako hodnotená pomocou piatich hodnotiacich kritérií.

Navrhnutý model GA-NN správne klasifikoval 941 podnikov z celkového súboru 1 024 podnikov na tréningovej vzorke, pričom celkovo presnejšie klasifikoval zdravé podniky (498 prípadov) ako podniky v úpadku (443 prípadov). Relatívne vyššie chyby model zaznamenal pri posudzovaní podnikov v úpadku, keď ich v 52 prípadoch označil ako zdravé podniky. Na testovacej vzorke podnik správne klasifikoval 234 prípadov a podobne ako na tréningovej vzorke bol presnejší pri hodnotení finančnej situácie zdravých podnikov.

1 Približne rovnaký podiel (od 70–85) bol použitý aj v doterajších empirických štúdiách; napr. Oreski a Oreski (2014); Zhou a kol. (2015); Chen a kol. (2011).

2 Pozri napr. Brabazon a Keenan (2004).

**Tabuľka 5 | Parametre hybridného modelu GA-NN**

Parameter	Hodnota
<b>Algoritmus učenia</b>	Genetické algoritmy
<b>Celkový počet vstupných premenných</b>	12
<b>Počet premenných v binárnom reťazci</b>	6
<b>Veľkosť populácie</b>	50
<b>Počet generácií</b>	70
<b>Miera križenia</b>	50 %
<b>Pravdepodobnosť mutácie</b>	1 %
<b>Elitné chromozómy</b>	1
<b>Fitness funkcia</b>	Predikčná presnosť
<b>Charakter závislej premennej</b>	Binárna (1 – podnik v úpadku, 0 – zdravý podnik)
<b>Metóda selekcie</b>	Ruletové koleso
<b>Počet neurónov v skrytej vrstve</b>	2
<b>Prah</b>	0,01
<b>Počet opakovaní procesu tréningu</b>	3
<b>Chybová funkcia</b>	SSE (suma rozdielu štvorcov)
<b>Aktivačná funkcia</b>	Logistická funkcia
<b>Podiel tréningová: testovacia vzorka</b>	80:20

Zdroj: vlastné spracovanie

**Tabuľka 6 | Kontingenčná tabuľka výsledkov modelu GA-NN**

Tréningová vzorka (n = 1 024)		Skutočný stav	
		B (podnik v úpadku)	NB (zdravý podnik)
Predikcia	B (podnik v úpadku)	443	32
	NB (zdravý podnik)	51	498
Testovacia vzorka (n = 256)		Skutočný stav	
		B (podnik v úpadku)	NB (zdravý podnik)
Predikcia	B (podnik v úpadku)	105	15
	NB (zdravý podnik)	7	129

Zdroj: vlastné spracovanie

### 3.4 Porovnanie predikčnej schopnosti modelov

V príspevku boli navrhnuté tri predikčné modely úpadku podnikov, ktorých klasifikačná presnosť bola postupne hodnotená na základe piatich hodnotiacich kritérií. V nasledujúcich riadkoch predkladáme dosiahnuté výsledky navrhnutých modelov (viz tabuľka 7).

**Tabuľka 7 | Zhodnotenie celkovej výkonnosti piatich modelov**

	Tréningová vzorka			Testovacia vzorka		
	MDA	BP-NN	GA-NN	MDA	BP-NN	GA-NN
<b>Chyba prvého druhu</b>	42,62 %	22,13 %	10,32 %	54,38 %	21,1 %	6,25 %
<b>Chyba druhého druhu</b>	33,33 %	14,67 %	6,04 %	18,03 %	9,38 %	10,42 %
<b>Presnosť predikcie</b>	61,86 %	81,15 %	91,89 %	64,41 %	84,77 %	91,22 %
<b>G-priemer</b>	0,678	0,7926	0,9089	0,6524	0,8321	0,8927
<b>F-ukazovateľ</b>	0,6211	0,7851	0,8937	0,607	0,821	0,8941

Zdroj: vlastné spracovanie

V rámci hodnotenia výkonnosti navrhnutých modelov môžeme jednoznačne konštatať, že MDA model dokázal správne klasifikovať zdravé podniky a podniky v úpadku s najnižším stupňom presnosti. Kým na tréningovej vzorke správne zaradil do binárnej skupiny 61,86 % podnikov, na testovacej vzorke 64,41 % podnikov. Takto nízka predikčná schopnosť modelu sa prejavila aj veľmi vysokými hodnotami najmä Chyby prvého druhu, čo znamená, že ak by bola užívateľom modelu MDA finančná inštitúcia poskytujúca úvery, ktorá hodnotí finančnú situáciu podniku týmto modelom, poskytla by úver 54,38 % podnikom, ktoré model označil za zdravé, pričom tie by sa v skutočnosti dostali do úpadku. Táto skutočnosť zreteľne poukazuje na neakceptovateľnosť využitia takéhoto modelu.

Výkonnosť modelu BP-NN je charakteristická v tom, že v porovnaní s tréningovou vzorkou (81,15 %) má testovacia vzorka vyššiu predikčnú schopnosť (84,77 %). Vyššia výkonnosť testovacej vzorky sa prejavila aj nižšími hodnotami Chyb prvého a druhého druhu v porovnaní s tréningovou vzorkou. Výrazne vyššie boli zaznamenané hodnoty pri Chybách prvej triedy, teda model bol výrazne presnejší pri klasifikovaní zdravých podnikov, ktoré označil za upadajúce. Vysoká hodnota Chyby prvého druhu stáže využiteľnosť modelu v podmienkach hodnotenia finančnej situácie podnikov pri poskytovaní úverových prostriedkov.

Hybridný model GA-NN mal spomedzi všetkých posudzovaných modelov najvyššiu predikčnú presnosť nielen na tréningovej vzorke (91,89 %), ale aj na testovacej (91,22 %). Predikčná presnosť testovacej vzorky modelu GA-NN sa výrazne nelísi od tréningovej vzorky, čo môžeme považovať za pozitívny signál vysokej generalizácie výsledkov

modelu. Túto klasifikačnú schopnosť model dosiahol evolučným procesom po trénovaní siete počas 70 generácií. Model len v 6,25 % prípadoch nesprávne klasifikoval podnik v úpadku ako zdravý podnik, zatiaľ čo v 10,42 % prípadoch označil zdravý podnik za upadajúci. Zaujímavé je, že na testovacej vzorke model dosiahol nižší stupeň Chyby prvého druhu (6,25 %) ako na tréningovej vzorke (10,42 %). Naopak Chyba druhého druhu bola vyššia na testovacej vzorke. Obidve zaznamenané hodnoty sú však uspokojivé a preto môžeme model označiť ako najvýkonnejší z navrhnutých modelov.

## Záver

Kedže v podmienkach Slovenskej republiky zahraničné predikčné modely nedisponujú dostatočným stupňom predikčnej presnosti, v predkladanej štúdií bol navrhnutý vlastný predikčný model GA-NN, ktorý je kombináciou genetických algoritmov využívaných na výber premenných a neurónovej siete na proces učenia dát a adaptácie funkčného vzťahu medzi vstupnými premennými.

Na porovnanie výkonnosti modelov boli vytvorené ďalšie dva modely, konkrétnie MDA model a BP-NN model. Predikčná presnosť modelov bola hodnotená piatimi kritériami: Chyba prvého druhu, Chyba druhého druhu, Presnosť predikcie, G-priemer a F-ukazovateľ. Modely boli vytvorené na tréningovej vzorke, pričom výsledky boli generalizované na testovacej vzorke podnikov.

Výsledky porovnávania výkonnosti modelov jednoznačne potvrdili predpoklad, že využitie hybridného modelu GA-NN prevyšuje výkonnosť ostatných modelov na skúmanej vzorke podnikov. Model GA-NN mal v rámci posudzovaných modelov najvyššiu predikčnú presnosť na tréningovej vzorke (91,89 %), ako aj na testovacej vzorke (91,22 %). Tieto výsledky na vzorkách sa výrazne nelisia, čo je dobrý predpoklad generalizácie výsledkov aj na iných vzorkách v budúcnosti. Navrhnutý model sa vyznačuje aj nízkymi podielmi Chyby prvého a druhého druhu (6,25 %, resp. 10,42 %) na testovacej vzorke podnikov. Dosiahnuté výsledky sú v súlade s empirickými zisteniami štúdií ako napr. Oreski a Oreski (2014); Liang a kol. (2015) či du Jardin (2017).

Možnosti využitia modelu GA-NN vnímame z viacerých perspektív. Model môže byť z makroekonomickej hľadiska využitý pri hodnotení finančnej stability krajiny ako nástroj odhadu kreditného rizika bánk, prípadne môže slúžiť aj ako analytický indikátor úveryschopnosti slovenských podnikov. Potenciál využitia vidíme napríklad aj v legislatíve, v ktorej sa v súčasnosti na identifikáciu úpadku využíva jedený ukazovateľ Vlastné imanie/ Záväzky. Myslíme si, že je reálne využívať nástroj v podobe modelu GA-NN, ktorý dokáže identifikovať podniky v úpadku s vyššou predikčnou presnosťou ako jeden ukazovateľ.

Z hľadiska interpretovateľnosti výsledkov modelu GA-NN musíme poukázať na jednu nevýhodu. Hoci tradičné štatistické modely sa vyznačujú nižšou klasifikačnou presnosťou, ich výsledky sú jednoduchšie interpretovateľné a je možné vyčísliť významnosť a prínos jednotlivých vstupných premenných pri predikcii výstupnej premennej. Výsledky modelov využívajúcich neurónové siete majú povahu čiernej skrinky, keďže nie je možné pozorovať ich vnútornú štruktúru a tak efektívne posúdiť výsledky. Tento

nedostatok však je kompenzovaný vyššou presnosťou predikcie na testovacej vzorke, ktorý presahuje 90 %. Ďalším nedostatom je malý rozsah použitých tréningových dát, ktorý vyplýva z výberu vzorky, v ktorej boli vybrané podniky v úpadku a k nim priradené zdravé údaje na základe stratifikovaného výberu vzorky. Väčší rozsah dát by mohol viest k zvýšeniu vypovedacej schopnosti a interpretovateľnosti modelov.

Ďalšou nedokonalosťou, ktorú je potrebné spomenúť, je závislosť na účtovných informáciách pri tvorbe modelu. To zo sebou prináša viacero nevýhod, ako napríklad (1) nedostatok teoretického základu modelu; (2) využité informácie majú historický charakter; (3) hodnoty v účtovných výkazoch môžu byť predmetom nekalých účtovných praktík, ktoré môžu spôsobiť ich zníženú reprezentatívnosť. Z metodologického hľadiska bolo potrebné zosúladiť účtovné závierky, ktorých štruktúra prešla v roku 2016 zmenou a bolo potrebné zachovať jednotu výpočtu ukazovateľov. Navyše, podniky sú dnes čoraz komplexnejšie, keďže trendom sú fúzie, akvizície, či prebratia zahraničnými spoločnosťami, ktoré stážajú výber vzorky a získavanie finančných ukazovateľov. Z uvedených dôvodov bude v budúcnosti dôležité zahrnúť tiež makroekonomicke ukazovatele, či kvalitatívne informácie.

Navrhnutý model je v budúcnosti možné aktualizovať, prehodnocovať a meniť parametre. Vyššia miera prispôsobenia architektúry modelu podmienkam ekonomickeho prostredia môže dokonca zvýšiť jeho predikčnú schopnosť. Ako možný smer vývoja modelu v budúcnosti považujeme jeho užšiu špecifikáciu. Väčšie uplatnenie by si mohol nájsť napríklad pri odhalovaní špecifickejšej vzorky z pohľadu veľkosti podnikov, veku podnikov či odvetvia.

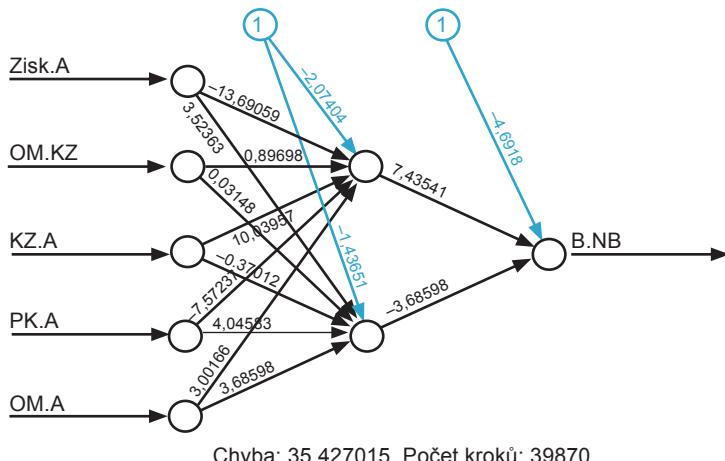
## Prílohy

### Príloha 1 | Procedúry genetického algoritmu

1. Definovať parametre modelu – kritérium zastavenia algoritmu, počet generácií, pravdepodobnosť mutácie, metóda selekcie, metóda priradenia fitness, veľkosť populácie, počet jedincov
2. Vytvoriť počiatok náhodný súbor  $m$  binárnych chromozómov
3. **opakuj**
4.     **Pre každý chromozóm**
5.         Trénuj model a vypočítaj fitness pre chromozómy
6.     **ukonči**
7.     **pre**  $k = 1 \dots$  veľkosť populácie /2 vykonaj:
8.         Vyber dva chromozómy na základe metódy Ruletové koleso
9.         Urob kríženie: náhodne vyber bod kríženia (loci) a zameň všetky gény v chromozóme za týmto bodom
10.         Mutácia: náhodne zameň binárne hodnoty génov v novom chromozóme potomka s pravdepodobnosťou  $p_m$
11.     **koniec**
12.     **pokiaľ** Nie je splnené kritérium zastavenia

Zdroj: vlastné spracovanie

### Príloha 2 | Topológia neurónovej siete s algoritmom backpropagation



Zdroj: vlastné spracovanie

**Príloha 3 | Deskriptívna štatistika premenných na vzorke všetkých podnikov**

Ukazovateľ	minimum	1.kvartil	medián	priemier	2.kvartil	maximum	št. odchýlka	šíkmost'	špicatosť	K-S test
<b>EBIT/Z prirážka</b>	-124,728 -3,067	-0,152 0,024	0,016 1,136	3,517 0,580	0,226 86,5	2 238,67 6,39	87,74 326 502,5	25,27 22,59	640,85 119,26	0,2171(0,000) 0,2966(0,000)
<b>DSZ</b>	-1958	87	205	21502	574	7 985 721	326 502,5	540,45	0,9954(0,000)	
<b>DOA</b>	-1	137	257	18661	636	3 656 019	195 973,6	13,89	215,98	0,9878(0,000)
<b>L3</b>	-12,893	0,406	0,955	2,351	1,738	101,277	6,89	8,51	92,63	0,4786(0,000)
<b>Z/A</b>	0,002	0,527	0,881	56,351	1,434	14 434,88	673,82	17,22	334,74	0,4908(0,000)
<b>Z/EBITDA</b>	-146 243,8	-3,37	0,80	-223,43	6,84	932,05	5 719,61	-25,44	646,55	0,4205(0,000)
<b>A/Z</b>	0,0001	0,697	1,136	5,510	1,896	528,1	34,6	11,39	143,06	0,5336(0,000)
<b>NM/A</b>	0,000	0,151	0,325	0,364	0,517	1,494	0,27	0,72	0,01	0,4893(0,000)
<b>PH/T</b>	-42,478	0,022	0,150	-0,047	0,363	1,000	2,29	-14,95	250,07	0,3012(0,000)
<b>EBITDA/A</b>	-3251	-0,136	0,04	-4,607	0,184	3 537,235	211,09	0,03	220,97	0,2446(0,000)
<b>PK/VI</b>	-78,841	0,384	0,910	1,258	1,105	341,220	14,51	19,47	459,95	0,4128(0,000)
<b>Z/VI</b>	-390,132	-1,767	0,373	2,422	2,298	355,585	31,11	1,25	76,31	0,2722(0,000)
<b>NOPAT/VI</b>	-15,106	0,028	0,251	0,512	0,808	67,016	3,18	14,46	295,41	0,3043(0,000)
<b>Zisk/Z</b>	-58,101	-0,155	0,003	3,465	0,172	2 238,444	87,62	25,38	644,37	0,2248(0,000)
<b>PH/OM</b>	-2 840,67	0,026	0,315	28,762	0,824	14 352,714	618,89	20,14	449,16	0,3028(0,000)
<b>FÚ/KZ</b>	-1,162	0,006	0,066	1,899	0,522	306,67	14,72	16,23	301,8	0,4618(0,000)
<b>EBIT/A</b>	-5 977,571	-0,176	0,013	-22,859	0,142	737,147	312,49	-15,81	269,27	0,2645(0,000)
<b>PK/NM</b>	-204 813	-1,05	0,16	-612,2	2,11	897,18	9 082,94	-9,43	408,15	0,2538(0,000)
<b>KZ/T</b>	-0,023	0,17	0,418	22,733	1,129	6 177,885	317,52	17,86	322,8	0,4878(0,000)
<b>DIKP</b>	-4 761,8	30,8	73,8	6 840,5	163,1	1 739 447	91 016,39	16,4	281,59	0,9755(0,000)
<b>Zisk/PH</b>	-2 682,4	-0,208	0,198	17,408	0,725	12 443,383	503,12	22,85	567,37	0,1850(0,000)
<b>PK/A</b>	-41 047,53	-0,43	0,06	-93,64	0,39	1,000	1 642,63	-23,84	588,29	0,1606(0,000)
<b>KZ/A</b>	-0,06	0,28	0,58	94,33	1,05	41 048,11	1 642,63	23,84	588,29	0,4878(0,000)
<b>CF/PH</b>	-2 682,4	0,007	0,379	18,362	0,845	12 443,383	502,41	22,94	570,43	0,2477(0,000)

Zdroj: vlastné spracovanie

#### Príloha 4 | Rozdiely v ukazovateľoch medzi dvoma skupinami a Mannov-Whitneyov test

Ukazovateľ	Všetky podniky				Zdravé podniky				Podniky v úpadku				Mann-Whitneyov U Test
	priemer	št. odchýlka	medián	priemer	št. odchýlka	medián	priemer	št. odchýlka	medián	priemer	št. odchýlka	medián	
<b>EBIT/Z prirážka</b>	3,517	87,74	0,016	0,91	4,72	0,17	6,12	124,04	-0,12	0,000*	0,000*	0,000*	
<b>DSZ</b>	1,136	6,39	0,197	1,12	4,03	0,32	1,15	8,1	0,07	0,000*	0,000*	0,000*	
<b>DOA</b>	21 502	326 502,5	205	603,34	4384,09	107,48	42400,08	461 128,4	406,45	0,000*	0,000*	0,000*	
<b>L3</b>	18 661	195 973,6	257	1 735,82	17312,89	220,53	35385	275 780,3	340,95	0,000*	0,000*	0,000*	
<b>Z/A</b>	2,351	6,89	0,955	3,96	9,29	1,57	0,74	1,9	0,45	0,000*	0,000*	0,000*	
<b>Z/EBITDA</b>	56,351	673,82	0,881	0,62	0,56	0,55	112,08	950,39	1,31	0,000*	0,000*	0,000*	
<b>A/Z</b>	-223,43	5 719,61	0,80	-0,81	103,05	2,58	-446,08	8 088,15	-2,28	0,000*	0,000*	0,000*	
<b>NM/A</b>	5,510	34,6	1,136	7,03	37,49	1,82	3,98	31,43	0,77	0,000*	0,000*	0,000*	
<b>PH/T</b>	0,364	0,27	0,325	0,29	0,23	0,23	0,44	0,28	0,42	0,000*	0,000*	0,000*	
<b>EBITDA/A</b>	-0,047	2,29	0,150	0,23	0,67	0,24	-0,33	3,15	0,06	0,000*	0,000*	0,000*	
<b>PK/VI</b>	-4,607	211,09	0,04	0,21	0,36	0,15	-9,43	298,68	-0,1	0,000*	0,000*	0,000*	
<b>Z/VI</b>	1,258	14,51	0,910	0,54	4,45	0,82	1,97	20,02	0,98	0,0786	0,0786	0,0786	
<b>NOPAT/VI</b>	2,422	31,11	0,373	1,41	29	0,9	3,43	33,1	-1,34	0,0678	0,0678	0,0678	
<b>Zisk/Z</b>	0,512	3,18	0,251	0,4	1,29	0,23	0,62	4,3	0,31	0,2126	0,2126	0,2126	
<b>PH/OM</b>	3,465	87,62	0,003	0,64	4,08	0,13	6,28	123,87	-0,13	0,000*	0,000*	0,000*	
<b>FÚ/KZ</b>	28,762	618,89	0,315	0,66	0,74	0,47	56,87	875,01	0,08	0,000*	0,000*	0,000*	
<b>EBIT/A</b>	1,899	14,72	0,066	3,67	20,66	0,48	0,12	0,99	0,01	0,000*	0,000*	0,000*	
<b>PK/NM</b>	-22,859	312,49	0,013	0,16	0,4	0,1	-45,88	441,06	-0,14	0,000*	0,000*	0,000*	
<b>KZ/T</b>	-612,2	9 082,94	0,16	7,22	22,2	1,45	-1 231,66	12 825,07	-0,78	0,000*	0,000*	0,000*	
<b>DIKP</b>	22,733	317,52	0,418	0,9	6,04	0,2	44,57	448,28	0,9	0,000*	0,000*	0,000*	
<b>Zisk/PH</b>	6 840,5	91 016,39	73,8	305,66	3 035,91	65,93	13 375,31	128 446,5	96,41	0,2563	0,2563	0,2563	
<b>PK/A</b>	-17,408	503,12	0,198	1,34	17,7	0,27	33,48	711,47	0,01	0,0675	0,0675	0,0675	
<b>KZ/A</b>	-93,64	1 642,63	0,06	0,27	0,54	0,32	-187,54	2321	-0,34	0,000*	0,000*	0,000*	
<b>CF/PH</b>	94,33	1642,63	0,58	0,48	0,51	0,36	188,18	2321	0,97	0,000*	0,000*	0,000*	
	18,362	502,41	0,379	1,22	14,29	0,44	35,5	710,49	0,21	0,1259	0,1259	0,1259	

Poznámka: \*p-hodnoty U testu, ktoré sú štatisticky významné na hladine významnosti  $\alpha = 0,05$

Zdroj: vlastné spracovanie

**Príloha 5 | Korelačná matrica finálneho súboru premenných**

	DSZ	L3	Z/EBITDA	A/Z	NM/A	PH/T	Zisk/A	FÚ/KZ	EBIT/A	Z/T	PK/A	KZ/A
<b>DSZ</b>	1,00											
<b>L3</b>	-0,02 (0,605)	1,00										
<b>Z/EBITDA</b>	0,00 (0,995)	0,01 (0,744)	1,00									
<b>A/Z</b>	-0,01 (0,816)	0,27 (0,00)*	0,01 (0,875)	1,00								
<b>NM/A</b>	0,09 (0,019)	-0,06 (0,115)	-0,01 (0,807)	0,13 (0,00)*	1,00							
<b>PH/T</b>	0,02 (0,668)	0,05 (0,171)	0,00 (0,990)	0,02 (0,628)	-0,01 (0,876)	1,00						
<b>Zisk/A</b>	0,00 (0,946)	0,00 (0,944)	0,00 (0,969)	0,20 (0,00)*	0,00 (0,924)	0,01 (0,744)	1,00					
<b>FÚ/KZ</b>	-0,01 (0,829)	0,30 (0,00)*	0,01 (0,897)	0,26 (0,00)*	-0,04 (0,334)	0,02 (0,636)	0,03 (0,499)	1,00				
<b>EBIT/A</b>	0,00 (0,965)	0,03 (0,522)	0,00 (0,943)	0,01 (0,760)	-0,01 (0,711)	0,01 (0,832)	0,01 (0,876)	0,01 (0,807)	1,00			
<b>Z/T</b>	0,29 (0,00)*	-0,02 (0,616)	0,00 (0,998)	-0,01 (0,803)	0,01 (0,806)	-0,05 (0,208)	0,00 (0,941)	-0,01 (0,815)	0,00 (0,939)	1,00		
<b>PK/A</b>	0,00 (0,941)	0,02 (0,619)	0,00 (0,959)	0,01 (0,816)	-0,01 (0,740)	0,00 (0,994)	0,01 (0,832)	0,01 (0,850)	0,35 (0,00)*	0,00 (0,933)	1,00	
<b>KZ/A</b>	0,00 (0,941)	-0,02 (0,619)	0,00 (0,958)	-0,01 (0,815)	0,01 (0,743)	0,00 (0,993)	-0,01 (0,831)	-0,01 (0,849)	-0,35 (0,00)*	0,00 (0,932)	-0,10 (0,00)*	1,00

Zdroj: vlastné spracovanie

## Literatúra

- Acosta-González, E., Fernández-Rodríguez, F. (2014). Forecasting Financial Failure of Firms Via Genetic Algorithms. *Computational Economics*, 43(2), 133–157, <https://doi.org/10.1007/s10614-013-9392-9>
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589–609, <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
- Back, B., Laitinen, T., Sere, K. (1996). Neural Networks and Genetic Algorithms for Bankruptcy Predictions. *Expert Systems with Applications*, 11(4), 407–413, [https://doi.org/10.1016/S0957-4174\(96\)00055-3](https://doi.org/10.1016/S0957-4174(96)00055-3)
- Brabazon, A., Keenan, P. B. (2004). A Hybrid Genetic Model for the Prediction of Corporate Failure. *Computational Management Science*, 1(3), 293–310, <https://doi.org/10.1007/s10287-004-0017-6>
- Corder, G. W., Foreman, D. I. (2014). *Nonparametric Statistics. A Step-by-Step Approach*. Hoboken: John Wiley & Sons. ISBN 978-1-118-84031-3.
- Delina, R., Packová, M. (2013). Validácia predikčných bankrotových modelov v podmienkach SR. *E+ M Ekonomie a Management*, 16(3), 101–112.
- Du, K. L., Swamy, N. S. (2014). *Neural Networks and Statistical Learning*. London: Springer-Verlag. ISBN 978-14-471-5571-3.
- du Jardin, P. (2016). A Two-stage Classification Technique for Bankruptcy Prediction. *European Journal of Operational Research*, 254(1), 236–252, <https://doi.org/10.1016/j.ejor.2016.03.008>
- Fidrmuc, J., Hainz, C. (2010). Default Rates in the Loan Market for SMEs: Evidence from Slovakia. *Economic Systems*, 34(2), 133–147, <https://doi.org/10.1016/j.ecosys.2009.10.002>
- Fedorova, E., Gilenko, E., Dovzhenko, S. (2013). Bankruptcy Prediction for Russian Companies: Application of Combined Classifiers. *Expert Systems with Applications*, 40(18), 7285–7293, <https://doi.org/10.1016/j.eswa.2013.07.032>
- Finlay, S. (2009). Are We Modelling the Right Thing? The Impact of Incorrect Problem Specification in Credit Scoring. *Expert Systems with Applications*, 36(5), 9065–9071, <https://doi.org/10.1016/j.eswa.2008.12.016>
- Gavurova, B., Packova, M., Misankova, M., Smrcka, L. (2017). Predictive Potential and Risks of Selected Bankruptcy Prediction Models in the Slovak Business Environment. *Journal of Business Economics and Management*, 18(6), 1156–1173, <https://doi.org/10.3846/16111699.2017.1400461>
- Gordini, N. (2014). A Genetic Algorithm Approach for SMEs Bankruptcy Prediction: Empirical Evidence from Italy. *Expert Systems with Applications*, 41(14), 6433–6445, <https://doi.org/10.1016/j.eswa.2014.04.026>
- Gorzałczany, M. B., Rudziński, F. (2016). A Multi-objective Genetic Optimization for Fast, Fuzzy Rule-based Credit Classification with Balanced Accuracy and Interpretability. *Applied Soft Computing*, 40, 206–220, <https://doi.org/10.1016/j.asoc.2015.11.037>
- Gunther, F., Fritsch, S. (2010). Neuralnet. Training of Neural Networks. *The R Journal*, 2(1), 30–38.
- Hair, J. F. a kol. (2014). *Multivariate Data Analysis*. Essex: Pearson Education Limited. ISBN 978-12-9202-190-4.
- Haupt, R. L., Haupt, S. E. (2004). *Practical Genetic Algorithms*. 2. vydanie. New Jersey: John Wiley & Sons. ISBN 0-471-45565-2.

- Kovacova, M., Kliestik, T. (2017). Logit and Probit application for the Prediction of Bankruptcy in Slovak Companies. *Equilibrium. Quarterly Journal of Economics and Economic Policy*, 12(4), 775–791, <https://doi.org/10.24136/eq.v12i4.40>
- Li, H., Sun, J., & Wu, J. (2010). Predicting Business Failure Using Classification and Regression Tree: An Empirical Comparison with Popular Classical Statistical Methods and Top Classification Mining Methods. *Expert Systems with Applications*, 37(8), 5895–5904, <https://doi.org/10.1016/j.eswa.2010.02.016>
- Liang, D., Lu, C. C., Tsai, C. F., Shih, G. A. (2016). Financial Ratios and Corporate Governance Indicators in Bankruptcy Prediction: A Comprehensive Study. *European Journal of Operational Research*, 252(2), 561–572, <https://doi.org/10.1016/j.ejor.2016.01.012>
- Marques, A. I., García, V., Sánchez, J. S. (2013). A Literature Review on the Application of Evolutionary Computing to Credit Scoring. *Journal of the Operational Research Society*, 64(9), 1384–1399, <https://doi.org/10.1057/jors.2012.145>
- Mihalovič, M. (2015). The Assessment of Corporate Financial Performance Via Discriminant Analysis. *Acta oeconomica Cassoviensis : Scientific Journal*, 8(1), 57–69.
- Min, S. H., Lee, J., Han, I. (2006). Hybrid Genetic Algorithms and Support Vector Machines for Bankruptcy Prediction. *Expert Systems with Applications*, 31(3), 652–660, <https://doi.org/10.1016/j.eswa.2005.09.070>
- Odom, M. D., Sharda, R. (1990). A Neural Network Model for Bankruptcy Prediction. In *Neural Networks, 1990., 1990 IJCNN International Joint Conference on* (pp. 163–168). IEEE. <https://doi.org/10.1109/IJCNN.1990.137710>
- Ohlson, J. A. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 18(1), 109–131, <https://doi.org/10.2307/2490395>
- Olson, D. L., Delen, D., Meng, Y. (2012). Comparative Analysis of Data Mining Methods for Bankruptcy Prediction. *Decision Support Systems*, 52(2), 464–473, <https://doi.org/10.1016/j.dss.2011.10.007>
- Oreski, S., Oreski, G. (2014). Genetic Algorithm-based Heuristic for Feature Selection in Credit Risk Assessment. *Expert Systems with Applications*, 41(4), 2052–2064, <https://doi.org/10.1016/j.eswa.2013.09.004>
- Ramachandran, K. M., Tsokos, C. H. P. (2009). *Mathematical Statistics with Applications*. London: Elsevier Academic Press. ISBN 978-0-12-374848-5.
- Shin, K. S., Lee, Y. J. (2002). A Genetic Algorithm Application in Bankruptcy Prediction Modeling. *Expert Systems with Applications*, 23(3), 321–328, [https://doi.org/10.1016/S0957-4174\(02\)00051-9](https://doi.org/10.1016/S0957-4174(02)00051-9)
- Sun, J., Li, H., Huang, Q. H., He, K. Y. (2014). Predicting Financial Distress and Corporate Failure: A Review from the State-of-the-art Definitions, Modeling, Sampling, and Featuring Approaches. *Knowledge-Based Systems*, 57, 41–56, <https://doi.org/10.1016/j.knosys.2013.12.006>
- Zięba, M., Tomczak, S. K., Tomczak, J. M. (2016). Ensemble Boosted Trees with Synthetic Features Generation in Application to Bankruptcy Prediction. *Expert Systems with Applications*, 58, 93–101, <https://doi.org/10.1016/j.eswa.2016.04.001>