

Aplikácia modelov predikcie bankrotu podnikov a posúdenie ich klasifikačnej schopnosti

doc. Ing. Jarmila Horváthová, CSc.*

Prešovská univerzita v Prešove

Katedra financií, účtovníctva a matematických metód

Konštantínova ul. 16, 080 01 Prešov, Slovakia

jarmila.horvathova@unipo.sk

doc. Ing. Martina Mokrišová, PhD.

Prešovská univerzita v Prešove

Katedra financií, účtovníctva a matematických metód

Konštantínova ul. 16, 080 01 Prešov, Slovakia

martina.mokrisova@unipo.sk

Abstrakt

Otázka bankrotu podnikov je v akademickom a podnikateľskom prostredí Slovenska stále aktuálna. Vo výskumoch a štúdiách sa aplikujú rôzne metódy predikcie bankrotu podnikov, a to s cieľom odhaliť model s najvyššou klasifikačnou presnosťou. Cieľom príspevku bolo vybrať model predikcie bankrotu, ktorý dosahuje najlepšie výkonnostné charakteristiky. Podkladom výberu boli výsledky výskumu autoriek, v rámci ktorého boli aplikované vybrané modely predikcie bankrotu podnikov. Prínosom príspevku je prehľad modelov predikcie bankrotu a výsledkov využitia vybraných modelov. Pridanou hodnotou príspevku je výber najvhodnejšej metódy z pohľadu aplikovateľnosti modelu a jeho klasifikačnej schopnosti pri predikcii bankrotu, ako aj z pohľadu obmedzení pri realizácii modelu a možností výberu vstupných charakteristík predikcie bankrotu. Vybraná metóda, resp. model a aplikované charakteristiky modelu budú predmetom budúcich výskumov autoriek. Vybraný model predikcie bankrotu a charakteristiky bankrotu môžu mať praktický význam pre manažérov analyzovanej vzorky podnikov pri riešení problematiky ako predchádzať finančnému zlyhaniu podnikov.

Kľúčové slová

bankrot, finančné zdravie, charakteristika, model, predikcia

Informácia

Tento príspevok je jedným z čiastkových výstupov v súčasnosti riešeného vedecko-výskumného grantu VEGA 1/0741/20.

1. Úvod

Diagnostikovanie finančného zdravia podnikov, ale aj predikcia ich možného finančného zlyhania, patria v súčasnosti k pomerne často diskutovaným témam. Najmä v záujme zachovania udržateľnosti a prosperity podnikov je veľmi dôležité vedieť v akej finančnej situácii sa nachádzajú. Predikcia bankrotu podnikov je aj

jednou z významných tém, ktoré sa často rozoberajú vo vedeckej literatúre zameranej na danú problematiku (Hassan a kol. 2017). Podľa Klieštika a kol. (2019) podnik môže zbankrotovať ak celkové záväzky prevyšujú reálnu hodnotu celkového majetku podniku. Na druhej strane môže firma vyhlásiť bankrot vzhľadom na platnú legislatívu danej krajiny. Z metodického hľadiska je predikcia bankrotu problémom binárnej klasifikácie, ktorej cieľom je čo najlepšie odlíšiť skupinu podnikov, ktoré sú solventné od skupiny nesolventných podnikov (Kristóf a Virág 2020). Napriek tomu, že existuje široké spektrum metód, využívaných pri predikcii zlyhania podnikov, ktoré majú aj vysokú spoľahlivosť predikcie bankrotu, 100% istota pri tejto predikcii zostáva nedosiahnuteľným cieľom. Táto skutočnosť vyplýva predovšetkým z vysokej komplexnosti činnosti podnikov, z ich úzkeho prepojenia so značným množstvom externých subjektov a z toho vyplývajúceho veľkého množstva relevantných vplyvov. Na základe toho sa pri predikcii zlyhania a bankrotu podnikov je potrebné zamerať na zistenie pravdepodobnosti s akou zlyhanie nastane. Úspešnosť predikcie zlyhania podnikov v zásade závisí od vstupných údajov podnikov a od metódy ich spracovania (Sivák a kol. 2004).

V tomto príspevku sú porovnané klasifikačné schopnosti výsledkov vybraných metód a modelov, ktoré boli aplikované autorkami v rámci ich výskumu v danej oblasti. Cieľom príspevku bolo vybrať model, ktorý dosahuje najlepšiu výkonnosť a klasifikačnú schopnosť. V súlade s uvedeným cieľom príspevku bolo potrebné porovnať výkonnosť vybraných predikčných modelov a vybrať ten model, ktorý je najvýkonnejší a dosahuje najlepšie porovnávacíe charakteristiky. Štruktúra príspevku je nasledovná. Kapitola 2 obsahuje prehľad metód a modelov, ktoré je možné aplikovať v oblasti predikcie bankrotu podnikov. Kapitola 3 sa venuje popisu výskumnej vzorky a uvádza aplikované metódy predikcie bankrotu podnikov v danej štúdií. V kapitole 4 sú uvedené dosiahnuté výsledky, a to celková klasifikačná schopnosť, klasifikačná presnosť v oblasti predikcie bankrotujúcich a nebankrotujúcich podnikov, Area Under the Receiver Operating Characteristic Curve (AUC) a diskusia k dosiahnutým výsledkom. Kapitola 5 je venovaná záverom, limitom výskumu, smerovaniu budúceho výskumu a uvádza celkový prínos výskumu.

2. Základné teoretické východiská

Predikčné modely prešli významným historickým vývojom, a to najmä z pohľadu aplikovaných predikčných metód. V rannom období ich vývoja bola veľmi populárna diskriminačná analýza (DA). Jednorozmernú diskriminačnú analýzu použil Beaver (1966, 1968). Finančné zdravie spoločností však má viacrozmernej charakter, ktorý nebol zachytený Beaverovým prístupom (Serrano-Cinca a Gutiérrez-Nieto 2013). Preto Altman (1968) zaviedol použitie viacrozmernej diskriminačnej analýzy, ktorú v ďalšom období aplikovali mnohí autori, ako napr. Deakin (1972), Wilcox (1973), Blum (1974) Elam (1975) Altman a kol. (1977) Norton a Smith (1979), Taffler (1983). Použitie viacrozmernej diskriminačnej analýzy si vyžaduje splnenie viacerých predpokladov. Prvým z nich je predpoklad viacrozmernej normality rozdelenia pravdepodobnosti vysvetľujúcich premenných. Ďalším predpokladom je rovnosť variačno-kovariančných matíc. Pri použití diskriminačnej analýzy je takisto potrebné odstrániť multikolinearitu a odľahlé hodnoty (Meloun a kol. 2017), avšak tieto predpoklady je potrebné splniť aj pri aplikácii iných metód. Napriek požiadavke naplnenia uvedených predpokladov patrí táto metóda k často aplikovaným aj v súčasnom období. Z novších štúdií, v ktorých bola aplikovaná viacrozmernej diskriminačná analýza (DA) ako predikčná metóda, možno spomenúť štúdie autorov Bhandari a Iyer (2013), Jaki a Cwiek (2020), Sari a kol. (2022). Výsledky DA boli porovnávané s výsledkami ďalších metód predikcie bankrotu v štúdiách autorov Du Jardin (2017), Zelenkov a kol. (2017), Alaka a kol. (2018), Hosaka (2019).

V 80-tych rokoch 20. storočia sa dostali do popredia modely predikcie bankrotu vyvinuté s využitím metódy podmienenej pravdepodobnosti. V roku 1970 Meyer a Pifer predstavili modely lineárnej pravdepodobnosti (Linear Probability Models - LPM). Tento prístup bol založený na lineárnom regresnom modeli s použitím metódy najmenších štvorcov. Metóda však bola kritizovaná, pretože predpokladané pravdepodobnosti LPM neležia medzi hodnotami 0 a 1 (Bhutta a Regupathi 2020). Preto boli tieto modely neskôr nahradené modelmi logistickej regresie (LR). Logistická regresia je zovšeobecnením lineárnej regresie. Používa sa predovšetkým na identifikovanie binárnych alebo viac - kategoriálnych závislých premenných. Keďže závislá premenná je diskretná, nie je možné ju modelovať lineárnou regresiou. Preto namiesto predpovedania toho či jav nastane alebo nie, sa vytvára model na predpovedanie pravdepodobnosti jeho výskytu (Olson a kol. 2012). V porovnaní s bežnou viacnásobnou regresiou a diskriminačnou analýzou má logistická regresia viacero výhod. Ako už bolo spomenuté, výsledné hodnoty predpokladaných pravdepodobností sú výhradne z intervalu $(0,1)$. Okrem toho Logit model nevyžaduje normálne rozdelenie hodnôt nezávislých premenných. To umožňuje zahrnúť do modelu aj také ukazovatele, ktoré by pri parametrickej diskriminačnej analýze nebolo možné aplikovať. Logit model nevyžaduje rovnosť variačno - kovariančných matíc (Gundová 2015). Medzi hlavné slabé stránky Logit modelov patrí ich mimoriadna citlivosť na multikolinearitu, odľahlé pozorovania a chýbajúce hodnoty (Hassan a kol. 2017). Prvýkrát bola metóda LR použitá pre predikciu bankrotu bánk Martinom (1977) a ako prvý ju pre podniky využil Ohlson (1980). K autorom, ktorí aplikovali model LR patria aj Jakubík a Teplý (2008), Hurtošová (2009), Tian a kol. (2015), Gulka (2016), Tong a Serrasqueiro (2021), Pacheco a kol (2022). Ďalším z modelov podmienenej pravdepodobnosti bol Probit model. Ako prvý ho aplikoval Zmijewski (1984). Z novších štúdií, v ktorých bol aplikovaný probit model pri predikcii insolventnosti a bankrotu je možné spomenúť štúdiu Arnis (2018).

V ďalšom období vzniklo viac ako 30 rôznych metód, ktoré pri predikcii bankrotu podnikov v prevažnej miere využívajú matematické programovanie a umelú inteligenciu. Jednou z najznámejších a najčastejšie používaných metód sú neurónové siete (Neural Networks - NN). Umelé neurónové siete (Artificial Neural Networks - ANN) sú skupinou učiacich sa štatistických modelov inšpirovaných biologickými neurónovými sieťami. Používajú sa na odhad alebo aproximáciu funkcií, ktoré môžu závisieť od veľkého počtu vstupov a sú vo všeobecnosti neznáme (Zhu a kol., 2021). Umožňujú riešiť klasifikačné, ako aj predikčné úlohy. Podľa Ciska a Klieštika (2013) sú neurónové siete často označované termínom „čierna skrinka“, a to z toho dôvodu, že nie je možné detailne poznať ich vnútornú štruktúru. Neurónové siete pri predikcii bankrotu aplikovali Odom a Sharda (1990), Altman a kol. (1994) Atiya (2001), Alfaro a kol. (2008), Tsai a Wu (2008), Olson a kol. (2012). Z novších štúdií je možné spomenúť autorov Hosaka (2019), Son a kol. (2019), Qian a kol. (2022).

Ďalšou zo známych metód aplikovaných v oblasti predikcie bankrotu sú rozhodovacie stromy (Decision Trees - DT), ktoré podľa Chou a kol. (2017) patria k najspoľahlivejším predikčným metódam. Rozhodovací strom je nelineárna diskriminačná metóda, ktorá využíva súbor nezávislých premenných na postupné rozdelenie vzorky do menších podskupín. Postup je iteratívny, v každej vetve stromu je cieľom vybrať nezávislú premennú, ktorá má najsilnejšiu asociáciu so závislou premennou podľa špecifického kritéria (Chen 2011). Najčastejšie používané typy rozhodovacích stromov sú ID3, C4.5, C5, CART (Classification and Regression Trees), Best First Decision Tree and AD Decision Tree (Olson a kol. 2012). Rozhodovacie stromy použili pri predikcii bankrotu Chen (2011), Olson a kol. (2012), Staňková a Hampel (2018). Špeciálny druh „Bagging ensembles“ využili autori Mantas a Abellán (2014).

V roku 2001 Sarkar a Sriram vytvorili modely Bayesovej siete (BN) na včasné varovanie pred zlyhaním bánk. Naivný Bayesov model patrí medzi štatistické techniky (Zhou a Lai 2016). Je založený na podmienených pravdepodobnostiach. Berie do úvahy historické údaje a používa Bayesovu vetu na výpočet pravdepodobnosti výskytu predmetného javu, vzhľadom na pravdepodobnosť výskytu iného javu, ktorý už nastal v minulosti (Serrano-Cinca a Gutiérrez-Nieto 2013). Výhodou modelov Bayesových sietí je, že nekladú

© Published by Journal of Global Science.

This is an Open Access article distributed under the terms of the Creative Commons Attribution License which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. The moral rights of the named author(s) have been asserted.

žiadne podmienky na rozdelenie pravdepodobnosti atribútov a je možné ich aplikovať na datasety s chýbajúcimi údajmi.

Na prelome 20. a 21. storočia boli v oblasti predikcie bankrotu aplikované aj ďalšie metódy ako napríklad Rough set theory alebo genetické algoritmy. Genetické algoritmy boli použité pri predikcii bankrotu v štúdiách Shin a Lee (2002), Etemadi a kol. (2009), Gordini (2014), Bateni a Asghari (2020). Jedným z najznámejších metód strojového učenia je Support Vector Machine (SVM), vytvorená v roku 1998 autormi Vapnik a Vapnik (Bhutta a Regupathi 2020). Využíva sa v klasifikačných aj v predikčných úlohách, pričom je možné rozlíšiť lineárne a nelineárne SVM. Support vector machines boli použité pri predikcii bankrotu autormi Huang a kol. (2004), Min a Lee (2005), Shin a kol., (2005), Martens a kol. (2008), Olson a kol. (2012), Staňková a Hampel (2018).

V poslednom období sa pri predikcii bankrotu podniku stále viac dostáva do popredia metóda Data Envelopment Analysis (DEA), ktorá je založená na lineárnom programovaní. Je zaradená medzi metódy viackriteriálneho rozhodovania, v ktorých je hodnotená relatívna miera efektívnosti posudzovaných jednotiek (Staníčková a Melecký 2011). Prvá myšlienka spojená s využitím metódy DEA na predikciu bankrotu bola zaznamenaná Simakom (1997), ktorý ako prvý porovnal jej výsledky s výsledkami Altmanovho Z – skóre. V čase, keď tento model aplikoval, neboli ešte modely DEA aplikované v súvislosti s predikciou bankrotu. Ukázalo sa, že tento výskum má rôzne aplikačné možnosti. Ďalšími autormi, ktorí sa venovali predikcii bankrotu s využitím DEA boli Cielen a kol. (2004). Títo autori použili na predikciu bankrotu radiálny model DEA a jeho výsledky porovnali s výsledkami diskriminačnej analýzy. V tom istom roku Paradi a kol. (2004) aplikovali aditívny a radiálny model s využitím peeling techniky. Model dosiahol 100% úspešnosť predikcie bankrotujúcich podnikov. Premachandra a kol. v roku 2009 použili aditívny model DEA a jeho výsledky porovnali s výsledkami LR. Výsledkom tohto výskumu bola uspokojivá miera korektnej predikcie bankrotu. Menej presná už bola miera predikcie finančne zdravých podnikov. Sueyoshi a Goto v roku 2009 aplikovali aditívny model DEA a vytvorili hranicu bankrotujúcich podnikov. Výsledky následne porovnali s DEA-DA prístupom.

Klasické (statické) DEA modely sú konštruované na jedno časové obdobie. Mnohí autori sa však zaujímajú o zmenu efektívnosti v priebehu času, čo môže poskytnúť obzvlášť dôležité informácie pre predikciu finančnej tiesne (Li a kol. 2017). Uvedení autori rozšírili prierezové DEA modely o faktor času a tak aplikovali Malmquistov index (MI) založený na metóde DEA. Použili údaje 742 čínskych podnikov kótovaných na burze, ktoré sledovali počas 10 rokov. Výsledky ich štúdie ukázali, že MI ponúka pohľad na konkurenčnú pozíciu spoločnosti a presné predpovede finančnej tiesne založené na miere efektívnosti vypočítanej pomocou DEA. Jednou z najinovatívnejších metód v oblasti predikcie bankrotu je metóda Graf theory (GT). Táto metóda bola aplikovaná v mnohých vedných oblastiach a v poslednom období sa objavujú jej aplikácie aj v oblasti predikcie finančného zlyhávania podnikov (Heo a Yang 2014).

3. Dáta a metodológia

Výskum bol realizovaný na vzorke podnikov z odvetvia stavebný priemysel. Stavebníctvo je dôležitým odvetvím nielen pre slovenskú ekonomiku, ale aj pre ekonomiku každej krajiny. To potvrdzuje Hafiz a kol. (2015), podľa ktorých je stavebný priemysel jedným z najdôležitejších pre hospodárstvo každej krajiny, a to aj napriek vysokej miere zlyhaní podnikov v tomto odvetví. Význam stavebníctva pre slovenskú ekonomiku zdôraznil aj Štrba (2020), ktorý konštatuje, že zatiaľ čo pred krízou bol za hlavný pilier slovenskej ekonomiky považovaný automobilový priemysel, odborníci sa v súčasnosti zhodujú na tom, že oživeniu hospodárstva v recesii môže najviac pomôcť stavebníctvo.

Stavebníctvo je hlavným realizátorom budov a stavieb, ktoré sú dôležitou súčasťou investícií, resp. tvorby hrubého fixného kapitálu v hospodárstve SR (MDVSR 2019). Je tiež dôležitým ukazovateľom konjunkturálneho vývoja celého hospodárstva, je úzko späté s odchýlkami a pohybmi v ekonomike. Bezprostredne reaguje na zmeny v ekonomickom cykle a má multiplikačný účinok na rozvoj ostatných sektorov. To znamená, že investície do stavebníctva spúšťajú v ekonomike krajiny celý reťazec dopytu po tovaroch a službách v styčných sektoroch, čo sa priaznivo prejavuje najmä v oblasti ekonomických aktivít, zamestnanosti a spätne v bilancii verejných rozpočtov.

Odvetvie stavebníctva spotrebováva veľké množstvo rôznych druhov energií, nerastných surovín a materiálov. Na druhej strane toto odvetvie produkuje obrovské množstvo stavebného odpadu, demolačných materiálov a emisií. Z tohto pohľadu je vzťah medzi stavebnou činnosťou a životným prostredím na jednej strane a trvalo udržateľným rozvojom na strane druhej veľmi dôležitý. Dodržiavanie zásad trvalo udržateľného rozvoja je preto pre stavebný priemysel obzvlášť dôležité.

Od vzniku samostatnej Slovenskej republiky prešlo stavebníctvo zásadnou zmenou v type vlastníctva spoločností. V súčasnosti majú rozhodujúce postavenie súkromné firmy, ktoré nahradili bývalé štátne organizácie. V oblasti výstavby budov (bytových a nebytových) sa postupne znižoval počet zamestnancov, najmä u veľkých stavebných spoločností. Na druhej strane tieto spoločnosti kapitálovo rástli. Okrem zahraničných investorov mali na investíciách na tomto trhu výraznejší podiel aj domáce firmy a developeri, ktorí v uplynulom období rozbehli veľké množstvo projektov (MDVSR 2019).

Výsledky stavebného priemyslu sú tiež dôležitým ukazovateľom konjunkturálneho vývoja celého hospodárstva, je úzko späté s odchýlkami a pohybmi v ekonomike. Bezprostredne reaguje na zmeny v ekonomickom cykle a má multiplikačný účinok na rozvoj ostatných sektorov. To znamená, že investície do stavebníctva spúšťajú v ekonomike krajiny celý reťazec dopytu po tovaroch a službách v styčných sektoroch, čo sa priaznivo prejavuje najmä v oblasti ekonomických aktivít, zamestnanosti a spätne v bilancii verejných rozpočtov.

Sektorová analýza slovenského stavebníctva spracovaná spoločnosťou Euler Hermes v roku 2019 poukazuje aj na negatívne javy v slovenskom stavebníctve. Ide najmä o značný podiel insolvenčných (v roku 2018 bol tento podiel 26,8%) a horšiu platobnú morálku dlžníkov. Napriek tomu, že platobné podmienky v tomto sektore sú často stanovené na 90/120 dní, záväzky sú spravidla splatené 7-30 dní po dátume splatnosti. Stavebníctvo spolu so sektorom služieb generuje najväčšie množstvo nedobytných pohľadávok v ekonomike (Krokoš 2019).

Vo výskume boli aplikované viaceré metódy a modely predikcie bankrotu. Je potrebné spomenúť najmä matematické programovanie a metódu DEA, ktorá bola aplikovaná s rôznym výberom vstupných charakteristík modelu. Okrem statického modelu DEA bol aplikovaný aj dynamický model, a to Malmquistov index (MI). Ďalej boli aplikované metódy Neurónová sieť (NN), Naivný Bayes (NB), Rozhodovací strom (DT), Gradient Boosted rozhodovací strom (GBDT), AdaBoost rozhodovací strom (ABDT), prístup s využitím Grafickej metódy modelovania (GTA), Metóda strojového učenia sa (SVM) a Logistická regresia (LR). Ich výkonnosť bola porovnaná s využitím celkovej klasifikačnej schopnosti, klasifikačnej schopnosti bankrotujúcich (senzitivita) a nebankrotujúcich podnikov (špecificita). Pre porovnanie klasifikačnej schopnosti jednotlivých modelov bola použitá aj hodnota AUC.

4. Výsledky a diskusia

Dosiahnuté výsledky jednotlivých aplikovaných metód sú uvedené v tabuľke 1. Najviac modelov bolo realizovaných s aplikáciou metódy DEA, keďže v prípade týchto modelov boli vstupné charakteristiky vybrané s využitím metódy výberu podľa experov (Domain Knowledge - DK) a s využitím metódy LASSO (Least Absolute Shrinkage and Selection Operator).

Tabuľka 1 Výsledky modelov predikcie bankrotu podnikov

Predikčný model	Charakteristiky	Celková klasifikačná presnosť	Senzitivita	Špecificita	AUC
DEA VRS DK	Výnosy/ majetok, Krátkodobý majetok/ krátkodobé záväzky, Čistý pracovný kapitál / majetok, Rentabilita majetku s EAT, Rentabilita vlastného kapitálu, Netto cash flowú záväzky a Záväzky/ majetok.	79,63%	97,01%	78,72%	0,93
DEA VRS LASSO	Záväzky/ majetok, Rentabilita nákladov, Rentabilita vlastného kapitálu, Krátkodobé záväzky/ majetok, Čistý pracovný kapitál/ majetok, Netto cash flow/ majetok a Obrat majetku.	86,29%	79,10%	86,66%	0,91
DEA VRS DK	Bežná likvidita, Čistý pracovný kapitál/ majetok, Rentabilita majetku, Rentabilita vlastného kapitálu, Rentabilita tržieb, Tržby/ majetok, Nerozdelený zisk/ majetok, Záväzky/ majetok, Miera zadlženosti, Doba obratu pohľadávok, Doba obratu záväzkov, Doba obratu zásob.	70,34%	95,24%	68,63%	0,85
DEA VRS LASSO	Čistý pracovný kapitál/ majetok, Tržby/ majetok, Doba obratu zásob, Rentabilita vlastného kapitálu, Nerozdelený zisk/ majetok, Záväzky /majetok, Miera zadlženosti, Čistý zisk/ majetok, Rentabilita nákladov, Krátkodobé záväzky/ majetok.	76,15%	61,90%	77,12%	0,71
MI DK	Bežná likvidita, Čistý pracovný kapitál/ majetok, Rentabilita majetku, Rentabilita vlastného kapitálu, Rentabilita tržieb, Tržby/ majetok, Nerozdelený zisk/ majetok, Záväzky/ majetok, Miera zadlženosti, Doba obratu pohľadávok, Doba obratu záväzkov, Doba obratu zásob.	86%	52%	88%	0,62
MI LASSO	Čistý pracovný kapitál/ majetok, Tržby/ majetok, Doba obratu zásob, Rentabilita vlastného kapitálu, Nerozdelený zisk/ majetok, Záväzky /majetok, Miera zadlženosti, Čistý zisk/ majetok, Rentabilita nákladov, Krátkodobé záväzky/ majetok.	75%	67%	75%	0,69


Predikčný model	Charakteristiky	Celková klasifikačná presnosť	Senzitivita	Špecificita	AUC
GTA	Krátkodobý majetok/ krátkodobé záväzky, Rentabilita majetku, Tržby/ majetok, Celková zadlženosť, Krátkodobé záväzky/ tržby.	95,16%	72,22%	97,62%	0,85
DT	Celková zadlženosť, Rentabilita nákladov, Rentabilita vlastného kapitálu, Čistý pracovný kapitál/ majetok, Krátkodobé záväzky/ majetok, Netto cash flow/ majetok, Tržby/ majetok.	98,88%	85,27%	92,05%	0,92
GBDT	Celková zadlženosť, Rentabilita nákladov, Rentabilita vlastného kapitálu, Čistý pracovný kapitál/ majetok, Krátkodobé záväzky/ majetok, Netto cash flow/ majetok, Tržby/ majetok.	99,07%	94,07%	100%	0,97
ABDT	Celková zadlženosť, Rentabilita nákladov, Rentabilita vlastného kapitálu, Čistý pracovný kapitál/ majetok, Krátkodobé záväzky/ majetok, Netto cash flow/ majetok, Tržby/ majetok.	99,07%	94,07%	100%	0,97
NN	Celková zadlženosť, Rentabilita nákladov, Rentabilita vlastného kapitálu, Čistý pracovný kapitál/ majetok, Krátkodobé záväzky/ majetok, Netto cash flow/ majetok, Tržby/ majetok.	97,04%	69,23%	98,44	0,84
NB	Celková zadlženosť, Rentabilita nákladov, Rentabilita vlastného kapitálu, Čistý pracovný kapitál/ majetok, Krátkodobé záväzky/ majetok, Netto cash flow/ majetok, Tržby/ majetok.	96,66%	8,62%	97,28%	0,91
SVM	Celková zadlženosť, Rentabilita nákladov, Rentabilita vlastného kapitálu, Čistý pracovný kapitál/ majetok, Krátkodobé záväzky/ majetok, Netto cash flow/ majetok, Tržby/ majetok.	97,77%	61,53%	99,61%	0,81
LR	Celková zadlženosť, Rentabilita nákladov, Rentabilita vlastného kapitálu, Čistý pracovný kapitál/ majetok, Krátkodobé záväzky/ majetok, Netto cash flow/ majetok, Tržby/ majetok.	97,77%	53,84%	100%	0,70

Zdroj: vlastné spracovanie

Poznámky: DEA VRS DK – Obálková analýza dát s aplikáciou modelu variabilných výnosov z rozsahu a s výberom charakteristík podľa expertov, DEA VRS LASSO - Obálková analýza dát s aplikáciou modelu variabilných výnosov z rozsahu a s výberom charakteristík podľa metódy LASSO MI DK – Malmquist index s aplikáciou charakteristík podľa expertov, MI LASSO - Malmquist index s výberom charakteristík s využitím metódy LASSO, GTA – prístup s využitím grafickej metódy modelovania , DT – rozhodovací strom, GBDT – Gradient Boosted rozhodovací strom, ABDT - AdaBoost rozhodovací strom, NN – Neurónová sieť, NB – Naivný Bayes, SVM – Metóda strojového učenia sa, LR – Logistická regresia

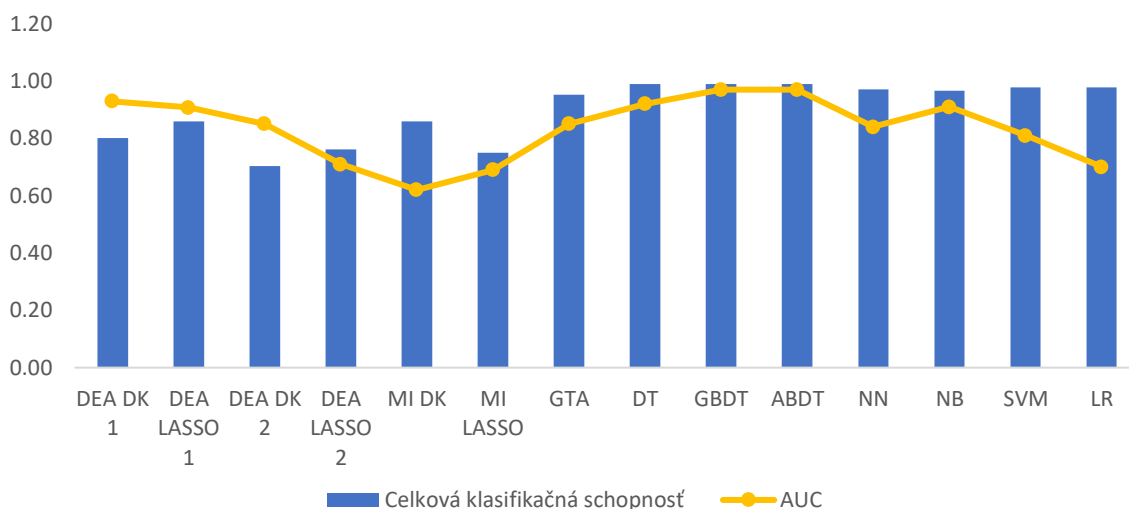
Aplikované modely na analyzovanej vzorke podnikov vykazujú dobré výsledky klasifikčnej schopnosti. Najlepšiu celkovú klasifikačnú schopnosť dosahujú modely GBDT a ABDT, potom nasleduje DT, následne SVM, LR, NN, NB, GTA, DEA. Z toho jednoznačne vyplýva, že klasifikačná alebo predikčná schopnosť je daná aplikovaným modelom, pričom jednoznačne vedú modely umelej inteligencie (rozhodovacie stromy). Je však potrebné poukázať na skutočnosť, že na vysokej klasifikačnej schopnosti modelov sa podieľa najmä vysoká klasifikačná schopnosť nebankrotujúcich podnikov. Najvyššiu klasifikačnú schopnosť v oblasti bankrotujúcich podnikov má model DEA VRS DK, najhoršiu dosiahol model LR. V prípade nebankrotujúcich podnikov dosiahli najlepšiu klasifikačnú schopnosť modely GBDT, ABDT, ale v tomto prípade sa týmto modelom vyrovnal

svojou klasifikačnou schopnosť model LR. Dosiagnuté výsledky pri aplikácii NN je možné porovnať so štúdiou Rafiei a kol. (2011), ktorí dosiahli 98,6% klasifikačnú schopnosť, čo je porovnateľný výsledkom s výsledkom dosiahnutým v tejto štúdiu. Tsai a Wu (2008) dosiahli vo svojej štúdiu pre tri vybrané datasety nasledovnú celkovú klasifikačnú schopnosť modelov NN: 97,32%, 78,97%, a 87,94%. Anandarajan a kol. (2001) dosiahli 89% klasifikačnú schopnosť NN, pričom klasifikačná schopnosť v prípade bankrotujúcich podnikov bola 70% a nebankrotujúcich bola 93, 83%. Aj v tejto štúdiu podobne ako v predkladanej štúdiu lepšiu predikčnú schopnosť je možné dosiahnuť pri predikcii nebankrotujúcich podnikov. Títo autori porovnali výsledky s výsledkami Viacnásobnej diskriminačnej analýzy (MDA) a zistili značné rozdiely. V prípade MDA bola klasifikačná schopnosť 55%, pričom presnosť pre bankrotujúce podniky bola 22%. Horák a kol. (2020) dosiahli najlepšiu klasifikačnú schopnosť NN 82,82%, presnosť klasifikácie nebankrotujúcich podnikov bola 93,79% a v prípade bankrotujúcich podnikov 56,20%. V prípade SVM dosiahli celkovú klasifikačnú schopnosť 76,08%, pre nebankrotujúce podniky 99,39% a bankrotujúce podniky 8,22%. Čo je veľmi nízka klasifikačná schopnosť. K autorom, ktorí použili rozhodovacie stromy patria napr. Aoki a kol. (2004), ktorí dosiahli 91,2% klasifikačnú schopnosť. V prípade klasifikačnej schopnosti DT v našej štúdiu ide o nižšiu hodnotu. Zibanezhad a kol. (2011), ktorí aplikovali DT dosiahli 94,5% celkovú klasifikačnú schopnosť modelu. Chen (2011) dosiahol vo svojom výskume tieto výsledky: celková klasifikačná schopnosť DT bola v jeho štúdiu 84,91%, klasifikácia nebankrotujúcich podnikov v DT bola 100% a bankrotujúcich 71,42%. V našej štúdiu bola dosiahnutá vyššia klasifikačná schopnosť bankrotujúcich podnikov (85,27%) v porovnaní s Chenom (2011). V prípade aplikácie NN Chen (2011) dosiahol tieto klasifikačné schopnosti: celková klasifikačná schopnosť modelu bola 90%, najvyššia klasifikačná schopnosť bankrotujúcich podnikov bola na úrovni 94, 28%. Táto hodnota prevyšuje hodnotu modelu v rámci našej štúdie. Aydin a kol. (2022) vo svojom výskume z oblasti predikcie bankrotu podnikov dosiahli nasledovné výsledky: v prípade aplikácie NN bolo 85,7% podnikov potvrdených ako nebankrotujúcich, 100% podnikov ako bankrotujúcich, pričom celková klasifikačná schopnosť bola 89,5%. Aydin a kol. (2022) aplikovali aj metódu DT a dosiahli nasledovné výsledky: celková klasifikačná schopnosť modelu bola 87,9%, presnosť klasifikácia bankrotujúcich modelov bola 92,9 % a nebankrotujúcich 86,4%. Pričom autori výskumu potvrdili, že výsledky sú závislé od toho, aká je aplikovaná vzorka podnikov, aký je počet podnikov, odvetvie z ktorého je vytvorená vzorka podnikov. Rovnako je dôležitý výber charakteristík bankrotu. Avšak jednoznačne je potvrdené, že modely umelej inteligencie dosahujú lepšie predikčné schopnosti. Výsledky presnosti odhadov dosiahnuté v našom výskume v prípade aplikácie modelu DEA je rovnako možné porovnať s výsledkami predchádzajúcich štúdií. Mendelová a Bieliková (2017) vo svojej štúdiu dosiahli presnosť odhadov pre spoločnosti vo finančnej tiesni 24 % a presnosť odhadov finančne zdravých podnikov 96,7 %. Boli skúmané aj prípady, v ktorých bola klasifikačná schopnosť modelu DEA pre neprosperujúce podniky vyššia - možno spomenúť výskum Mendelová a Stachová (2016) s klasifikačnou schopnosťou 10 - 42,86 %, štúdiu Premachandra a kol. (2009) s klasifikačnou schopnosťou 84, 89 %, resp. Cielen a kol. (2004), ktorí dosiahli klasifikačnú schopnosť modelu 74,4 - 75,7 %. V našom výskume sme dosiahli vysokú klasifikačnú schopnosť bankrotujúcich podnikov, a to najmä v prípade aplikácie ukazovateľov DK. Dosiagnuté výsledky boli nasledovné: klasifikačná schopnosť bankrotujúcich podnikov bola 97,01% a 95,25%. Celková klasifikačná schopnosť bola 79,63% a 70,34%. V štúdiách vyššie uvedených autorov je podobný alebo nižší výsledok celkovej klasifikačnej presnosti odhadu napr. Premachandra a kol. (2009) dosiahli 75 % – 77 %, Mendelová a Stachová (2016) 88 % – 95 % a Cielen a kol. (2004) 85,1 % – 86,4 %. Tieto výsledky sú porovnateľné s výsledkami tejto štúdie. Na grafe 1 sú zachytené výsledky celkovej klasifikačnej schopnosti, senzitivity a špecificity jednotlivých aplikovaných modelov.



Graf 1 Základné výstupné parametre aplikovaných modelov
Zdroj: vlastné spracovanie

Najlepšiu senzitivitu dosahuje model DEA DK, a to v oboch aplikovaných prípadoch, z čoho vyplýva, že pre predikciu bankrotu podnikov je dôležitý výber charakteristík, ktoré vstupujú do modelu. Model MIDK dosiahol najnižšiu senzitivitu čo bolo spôsobené tým, že tento model zachytáva vývoj vybraných charakteristík v čase. Model LR dosiahol najnižšiu senzitivitu. Špecifickosť väčšiny modelov kopíruje celkovú klasifikačnú presnosť modelov. Najvyššia špecifickosť a celková klasifikačná schopnosť modelov je v prípade aplikácie GBDT, ABDT, NN, NB, SVM a LR. Celkovo všetky modely vykazujú lepšie hodnoty špecifickosti ako senzitivity, okrem modelov DEA DK 1 a 2, čo nasvedčuje tomu, že výber charakteristík, ktoré sú využité v týchto modeloch je vhodnejší ako výber charakteristík s aplikáciou metódy LASSO. Porovnanie celkovej klasifikačnej schopnosti modelov ako aj ich AUC je zobrazené v grafe 2.



Graf 2 Celková klasifikačná schopnosť a AUC aplikovaných modelov
Zdroj: vlastné spracovanie

V prípade modelov DEA je hodnota AUC najvyššia. Táto hodnota potvrdila aj najvyššiu klasifikačnú schopnosť bankrotujúcich podnikov modelu DEA DK. Všetky modely dosahovali vysokú hodnotu špecifickosti, čiže predikcie nebankrotujúcich podnikov a v súvislosti s tým aj vysokú celkovú klasifikačnú schopnosť.

Jednoznačne, ak sa zameriame na výsledky predikcie možného bankrotu podnikov, vychádza ako najlepší predikčný model DEA s výberom ukazovateľov metódov DK (DEA DK). Z pohľadu nebankrotujúcich podnikov vychádzajú najlepšie rozhodovacie stromy, ktoré dosahujú hodnoty špecificity až 100%, v dôsledku čoho dosahujú vysoké hodnoty celkovej klasifikačnej schopnosti. Vysokú klasifikačnú schopnosť modelu DEA DK pre bankrotujúcich podnikov je možné zdôvodniť tým, že metóda DEA jednoznačne klasifikuje podniky, ktoré ležia na hranici finančnej tiesne a tým je jej klasifikačná schopnosť bankrotujúcich podnikov vyššia ako v prípade iných metód. Ide prioritne o metódu DEA s aplikáciou výberu ukazovateľov podľa expertov (DK).

5. Záver

V rámci príspevku boli porovnané výsledky viacerých výskumov, ktoré boli realizované v oblasti predikcie bankrotu vybraných podnikov. Cieľom príspevku bolo vybrať model, ktorý dosahuje najlepšiu klasifikačnú presnosť. Bola analyzovaná vzorka podnikov z oblasti stavebného priemyslu SR. Najlepšiu celkovú klasifikačnú schopnosť dosiahli modely umelej inteligencie (DT, NN), ale aj model LR. Najlepšiu klasifikačnú schopnosť v oblasti predikcie bankrotujúcich podnikov dosiahol model DEA DK, ktorý je založený na aplikácii vstupných charakteristík podľa expertov. Z toho vyplýva, že charakteristiky stanovené expertmi s aplikáciou vhodného modelu predikcie bankrotu môžu priniesť vynikajúce a signifikantné výsledky predikcie budúceho vývoja podnikov. V oblasti predikcie nebankrotujúcich podnikov najlepšiu klasifikačnú schopnosť dosiahli modely GBDT, ADBT a LR. Prínosom príspevku bolo zistenie, že modely umelej inteligencie a matematického programovania s výberom vhodných vstupných charakteristík dosahujú významnú klasifikačnú a predikčnú schopnosť. Limitáciou daného výskumu bola databáza údajov, ktorá mala niektoré nedostatky, ako chýbajúce údaje, odľahlé hodnoty, ako aj malý počet podnikov za viac rokov. Do budúcnosti bude potrebné venovať pozornosť tvorbe databázy údajov, ktorá bude kompaktná a bude odrážať vývoj podnikov z pohľadu ich finančného zdravia a výkonnosti.

Zoznam bibliografických odkazov

1. Alaka, H. A., Oyedele, L. O., Owolabi, H. A., Kumar, V., Ajayi, S. O., Akinade, O. O. a Bilal, M. , 2018. Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert Systems with Applications*, 94, 164–184. <https://doi.org/10.1016/j.eswa.2017.10.040>.
2. Alfaro, E., García, N., Gámez, M. a Elizondo, D., 2008. Bankruptcy forecasting: An empirical comparison of adaboost and neural networks. *Decision Support Systems*, 45(1), 110–122. <https://doi.org/10.1016/j.dss.2007.12.002>.
3. Altman, E. I., 1968. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance*, 23(4), 589–609. <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>.
4. Altman, E. I., Haldeman, R. G. a Narayanan, P., 1977. ZETA ANALYSIS, a new model to identify bankruptcy risk of corporations. *Journal of Banking and Finance*, 1(1), 29–54. [https://doi.org/10.1016/0378-4266\(77\)90017-6](https://doi.org/10.1016/0378-4266(77)90017-6).
5. Altman, E. I., Marco, G. a Varetto, F., 1994. Corporate distress diagnosis: comparisons using linear discriminant analysis and neural networks (the Italian experience). *Journal of Banking and Finance*, 18(3), 505–529. [https://doi.org/10.1016/0378-4266\(94\)90007-8](https://doi.org/10.1016/0378-4266(94)90007-8).
6. Anandarajan, M., Lee, P. a Anandarajan, A., 2001. Bankruptcy prediction of financially stressed firms: an examination of the predictive accuracy of artificial neural networks," *Intelligent Systems in Accounting, Finance and Management*, 10(2), 69–81. <https://doi.org/10.1002/isaf.199>.

7. Aoki, S., Hosonuma, Y. a Takayasu, H., 2004. Bankruptcy Prediction Using Decision Tree The Application of Econophysics. Pp. 299 -302. Springer Japan, Tokyo. SN - 978-4-431-53947-6. ID - 10.1007/978-4-431-53947-6_43.
8. Arnis, N., 2018. Predicting corporate bankruptcy: A cross-sectoral empirical study : the case of Greece. *International Journal of Business and Economic Sciences Applied Research*, 11(3), 31–56. <https://doi.org/10.25103/ijbesar.113.04>.
9. Atiya, A. F., 2001. Bankruptcy prediction for credit risk using neural networks: a survey and new results. *IEEE Transactions on Neural Networks*, 12(4), 929–935. <https://doi.org/10.1109/72.935101>.
10. Aydin, N., Sahin, N., Devenci, M. a Pamucar, D., 2022. Prediction of financial distress of companies with artificial neural networks and decision trees models, *Machine Learning with Applications*, Volume 10, 100432, ISSN 2666-8270.
11. Bateni, L. a Asghari, F., 2020. Bankruptcy Prediction Using Logit and Genetic Algorithm Models: A Comparative Analysis. *Computational Economics*, 55, 335–348. <https://doi.org/10.1007/s10614-016-9590-3>.
12. Beaver, W. H., 1966. Financial ratios as predictors of failure. In: *Journal of Accounting Research*, 4, 71–111. <https://doi.org/10.2307/2490171>.
13. Beaver, W. H., 1968. Alternative accounting measures as predictors of failure. *The Accounting Review*, 43(1), 113– 122.
14. Bhandari, S.B. a Iyer, R., 2013. Predicting business failure using cash flow statement based measures. *Managerial Finance*, 39(7), 667–676. <https://doi.org/10.1108/03074351311323455>
15. Bhutta, R. a Regupathi, A., 2020. Predicting corporate bankruptcy: Lessons from the past. *Asian Journal of Multidisciplinary Studies*, 8(1), 4-10.
16. Blum, M., 1974. Failing company discriminant analysis. *Journal of Accounting Research*, 12(1), 1–25.
17. Cielen A, Peeters L. a Vanhoof K., 2004. Bankruptcy prediction using a data envelopment analysis. *European Journal of Operational Research*, 154(2), 526–532. [https://doi.org/10.1016/S0377-2217\(03\)00186-3](https://doi.org/10.1016/S0377-2217(03)00186-3).
18. Cisko, Š. a Klieštk, T., 2013. Finančný manažment podniku II [Financial management of the company II]. Žilina: Edis.
19. Deakin, E. B. , 1972. A Discriminant Analysis of Predictors of Business Failure. *Journal of Accounting Research*, 10(1), 167–179. <https://doi.org/10.2307/2490225>.
20. Du Jardin, P., 2017. Dynamics of firm financial evolution and bankruptcy prediction. *Expert Systems with Applications*, 75, 25–43. <https://doi.org/10.1016/j.eswa.2017.01.016>.
21. Etemadi, H., Anvary Rostamy, A. A. a Dehkordi, H. F., 2009. A genetic programming model for bankruptcy prediction: Empirical evidence from Iran. *Expert Systems with Applications*, 36(2), 3199–3207. <https://doi.org/10.1016/j.eswa.2008.01.012>.
22. Elam, R., 1975. The effect of lease data on the predictive ability of financial ratios. *The Accounting Review*, 5(1), 25–43. Dostupné z: <https://www.jstor.org/stable/244661>.
23. 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>.
24. Gulka, M. , 2016. Model predikcie úpadku obchodných spoločností podnikajúcich v podmienkach SR. *BIATEC*, 24(6), 5-9. Dostupné z: https://www.nbs.sk/_img/Documents/_PUBLIK_NBS_FSR/Biatec/Rok2016/06-2016/Biatec_6_16_03Gulka.pdf.
25. Gundová, P., 2015. Metódy predikovania finančnej situácie podnikov. Banská Bystrica: Elianum.
26. Hafiz, A., Lukumon, O., Muhammad, B., Olugbenga, A., Hakeem, O. a Saheed, A., 2015. Bankruptcy Prediction of Construction Businesses: Towards a Big Data Analytics Approach. In *Proceedings of the 2015 IEEE First International Conference on Big Data Computing Service and Applications* (pp. 347-352), San Francisco, CA, USA, IEEE Computer Society.
27. Hassan, E., Zainuddin, Z., a Nordin, S., 2017. A review of financial distress prediction models: Logistic regression and multivariate discriminant analysis. *Indian-Pacific Journal of Accounting and Finance*, 1(3), 13-23. <https://doi.org/10.32890 / IPJAF.2017.1.3.15>.

28. Heo, J. a Yang, J.Y., 2014. Adaboost based bankruptcy forecasting in Korean construction companies. In: Applied Soft Computing, 24, Q, pp. 494 – 499. Holland, J. H. (1975). Adaptation in natural and artificial system. University of Michigan Press, Ann Arbor.
29. Horák, J., Vrbka, J. a Suler, P., 2020. "Support Vector Machine Methods and Artificial Neural Networks Used for the Development of Bankruptcy Prediction Models and their Comparison" *Journal of Risk and Financial Management* 13, no. 3: 60. <https://doi.org/10.3390/jrfm13030060>
30. Hosaka, T., 2019. Bankruptcy prediction using imaged financial ratios and convolutional neural networks. *Expert Systems with Applications*, 117, 287–299. <https://doi.org/10.1016/j.eswa.2018.09.039>.
31. Huang, Z., Chen, H., Hsu, C-J. Chen, W-H. a Wu, S., 2004. Credit rating analysis with support vector machines and neural networks: a market comparative study. *Decision Support Systems*, 37(4) (2004) 543–558. [https://doi.org/10.1016/S0167-9236\(03\)00086-1](https://doi.org/10.1016/S0167-9236(03)00086-1).
32. Hurtošová, J. , 2009. Construction of a Rating Model, a Tool for Assessing the Creditworthiness of a Company [Konštrukcia Ratingového Modelu, Nástroja Hodnotenia Úverovej Spôsobilosti Podniku]. Dizertačná práca, Ekonomická univerzita v Bratislave, Bratislava, Slovensko.
33. Chen, M-Y., 2011. Predicting corporate financial distress based on integration of decision tree classification and logistic regression. *Expert Systems with applications*, 38(9), 11261–11272. <https://doi.org/10.1016/j.eswa.2011.02.173>.
34. Chou, C-H., Hsieh, S-C. a Qiu, C-J. 2017. Hybrid genetic algorithm and fuzzy clustering for bankruptcy prediction. *Applied Soft Computing*, 56, 298–316. <https://doi.org/10.1016/j.asoc.2017.03.014>.
35. Jaki, A. a Ćwięk, W., 2020. Bankruptcy Prediction Models Based on Value Measures. *Journal of Risk and Financial Management*, 14(1), 1–14. <https://doi.org/10.3390/jrfm14010006>.
36. Jakubík, P. a Teplý. P., 2008. The prediction of corporate bankruptcy and Czech economy's financial stability through logit analysis, IES Working Paper. 2008, no. 19. Charles University in Prague, Institute of Economic Studies (IES), Prague.
37. Klieštik. T. a kol., 2019. Predikcia finančného zdravia podnikov tranzitívnych ekonomík. Žilinská univerzita v Žiline: EDIS.
38. MartinOhlsoKristóf, T. a Virág, M., 2020. A comprehensive review of corporate bankruptcy prediction in Hungary. In: *Journal of Risks and financial management*. Vol. 13, No. 2, pp. 111- 130. <https://doi.org/10.3390/jrfm13020035>.
39. Krokoš, A., 2019. Stavebný sektor na Slovensku [Construction sector in Slovakia]. Bratislava: Euler Hermes SA. Retrieved 01.08.2022 from <https://www.eulerhermes.com>.
40. Li, Z., Crook, J. a Andreeva, D., 2017. Dynamic prediction of financial distress using Malmquist DEA. *Expert Systems with Applications*, 80, 94–106. <https://doi.org/10.1016/j.eswa.2017.03.017>.
41. Mantas, C. J. a Abellán, J., 2014. Credal Decision Trees to Classify Noisy Data Sets. In M. Polycarpou, A.C.P.L.F de Carvalho, JS. Pan, M. Woźniak, H. Quintian & E. Corchado (Eds.). *Hybrid Artificial Intelligence Systems. HAIS 2014. Lecture Notes in Computer Science* (pp. 689–696). Cham: Springer. https://doi.org/10.1007/978-3-319-07617-1_60.
42. Martens, D. Bruynseels, L., Baesens, B., Willekens, M. a Vanthienen, J., 2008. Predicting going concern opinion with data mining, *Decision Support Systems*, 45(4), 765–777.
43. Martin, D. , 1977. Early warning of bank failure. A logit regression approach. *Journal of banking and finance*. 1(3), 249-276. [https://doi.org/10.1016/0378-4266\(77\)90022-X](https://doi.org/10.1016/0378-4266(77)90022-X).
44. Meloun, M., Militký, J. a Hill, M., 2017. *Statistická analýza vícerozměrných dat v příkladech*. Praha: Karolinum.
45. Meyer, P. A. a Pifer, H. W., 1970. Prediction of Bank failures. *The Journal of Finance*, 25(4), 853– 868. <https://doi.org/10.1111/j.1540-6261.1970.tb00558.x>.
46. Min, J. H. a Lee, Y-C., 2005. Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Applications*, 28(4). 603-614. <https://doi.org/10.1016/j.eswa.2004.12.008>.

47. MDVSR, 2019. Yearbook of the Slovak construction (2019). Bratislava: Ministry of Transport of the Slovak Republic. Retrieved 5.11.2023 from <https://www.mindop.sk/ministerstvo-1/vystavba-5/stavebnictvo/dokumenty-a-materialy/ro-cenky-stavebnictva>
48. Norton, C. L. a Smith, R. E. , 1979. A comparison of general price level and historical cost financial statements in the prediction of bankruptcy. *The Accounting Review*, 54(1), 72–87. Dostupné z: <https://www.jstor.org/stable/246235>.
49. Odom, M. D. a Sharda, R., 1990. A neural network model for bankruptcy prediction. In 1990 IJCNN International Joint Conference on Neural Networks (pp. 163–168 vol.2).
50. Ohlson, J. A. , 1980. Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, 18(1), 109-131.
51. Olson, D. L., Delen, D. a 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>.
52. Pacheco, L., Madaleno, M., Correia, P. a Maldonado, I., 2022. Probability of corporate bankruptcy: Application to Portuguese manufacturing industry SMEs. *International Journal of Business and Society*, 23(2), 1169–1189. <https://doi.org/10.33736/ijbs.4863.2022>.
53. Paradi, J. C., Asmild, M. a Simak, P. C., 2004. Using DEA and worst practice DEA in credit risk evaluation. *Journal of productivity analysis*. Vol. 21, No. 2, pp. 153-165. Retrieved February 2, 2019, from <https://www.jstor.org/stable/41770152>.
54. Premachandra, I. M., Bhabra, G. S. a Sueyoshi, T., 2009. DEA as a tool for bankruptcy assessment: A comparative study with logistic regression technique. *European Journal of Operational Research*, 193(2), 412-424. <https://doi.org/10.1016/j.ejor.2007.11.036>.
55. Qian, H., Wang, B., Yuan, M., Gao, S. a Song, Y., 2022. Financial distress prediction using a corrected feature selection measure and gradient boosted decision tree. *Expert Systems with Applications*, 190, 116202. <https://doi.org/10.1016/j.eswa.2021.116202>.
56. Rafiei, M. N., Manzari, S., M. a Bostanian, S., 2011. Financial health prediction models using artificial neural networks, genetic algorithm and multivariate discriminant analysis: Iranian evidence. *Expert systems with Applications*. 38 (8), pp. 10 210 – 10 217. ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2011.02.082>.
57. Sari, K. R., Martini, R., Almira, N., Hartati, S. a Husin, F., 2022. Prediction of Bankruptcy Risk Using Financial Distress Analysis. *Golden Ratio of Finance Management*, 2(2), 77–86. <https://doi.org/10.52970/grfm.v2i2.127>.
58. Sarkar, S. a Sriram, R. S., 2001. Bayesian models for early warning of bank failures, *Management Science* 47(11), 1457–1475. <https://doi.org/10.1016/j.dss.2012.11.015>.
59. Serrano-Cinca, C. a Gutiérrez-Nieto, B., 2013. Partial least square discriminant analysis for bankruptcy prediction. *Decision Support Systems*, 54(3), 1245–1255. <https://doi.org/10.1016/j.dss.2012.11.015>.
60. Shin, K-S. a 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).
61. Shin, K.S., Lee, T.S. a Kim, H.J., 2005. An application of support vector machines in bankruptcy prediction model, *Expert Systems with Applications*, 28(1) (2005) 127–135. <https://doi.org/10.1016/j.eswa.2004.08.009>.
62. Simak, P. C., 1997. DEA Based Analysis of Coporate Failure, Master Thesis, Faculty of Applied Sciences and Engineering, University of Toronto, Toronto. Dostupné z: <https://tspace.library.utoronto.ca/bitstream/1807/11746/1/MQ29433.pdf>.
63. Sivák, R. a kol., 2004. Riziko a neistota vo finanáciách. Bratislava: Ekonóm. ISBN 80-225-1956-1.
64. Son, H., Hyun, C., Phan, D. a Hwang, H. J., 2019. Data analytic approach for bankruptcy prediction. *Expert Systems with Applications*, 138, 112816. <https://doi.org/10.1016/j.eswa.2019.07.033>.
65. Staničková, M. a Melecký, L., 2011. Hodnocení konkurenceschopnosti Visegrádské čtyřky prostřednictvím aplikace CCR vstupově orientovaného modelu analýzy obalu dat. In: *Scientific Papers of the University of Pardubice, Series D: Faculty of Economics and Administration*, č. 4. s. 176-188. Dostupné na:

© Published by Journal of Global Science.

This is an Open Access article distributed under the terms of the Creative Commons Attribution License which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. The moral rights of the named author(s) have been asserted.

- https://dk.upce.cz/bitstream/handle/10195/42693/StanicikovaM_HodnoceniKonkurenceschopnosti_SP_FES_2011.pdf?isAllowed=y&sequence=1.
66. Staňková, M. a Hampel, D., 2018. Bankruptcy Prediction of Engineering Companies in the EU Using Classification Methods. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 66(5), 1347-1356. <https://doi.org/10.11118/actaun201866051347>.
 67. Sueyoshi, T. a Goto, M., 2009. Methodological comparison between DEA and DEA-DA from the perspective of bankruptcy assessment. *European Journal of Operational Research*, 188(2), 561-575. <https://doi.org/10.1016/j.ejor.2008.11.030>.
 68. Štrba, M., 2020. Will the construction industry drive the Slovak economy after the corona crisis? *Business center*. Retrieved 24.08.2023 from <https://podnikatelskecentrum.sk/rozhybe-stavebnictvo-po-koronakrize-slovensku-ekonomiku/>.
 69. Taffler, R. J. , 1983. The assessment of company solvency and performance using a statistical model. *Accounting and Business Research*, 13(52), 295–308. <https://doi.org/10.1080/00014788.1983.9729767>.
 70. Tian, S., Yu, Y. a Guo, H., 2015. Variable selection and corporate bankruptcy forecasts. *Journal of Banking & Finance*, 52, 89–100. <https://doi.org/10.1016/j.jbankfin.2014.12.003>.
 71. Tong, Y. a Serrasqueiro, Z., 2021. Predictions of failure and financial distress: A study on Portuguese high and medium-high technology small and mid-sized enterprises. *Journal of International Studies*, 14(2), 9–25. <https://doi.org/10.14254/2071-8330.2021/14-2/1>.
 72. Tsai, C. F. a Wu, J. W., 2008. Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert Systems with Applications*, 34(4), 2639– 2649. <https://doi.org/10.1016/j.eswa.2007.05.019>.
 73. Wilcox, J. W., 1973. A prediction of business failure using accounting data. *Journal of Accounting Research*, selected studies, 11, 163–179. <https://doi.org/10.2307/2490035>.
 74. Zelenkov, Y., Fedorova, E. a Chekrizov, D., 2017. Two-step classification method based on genetic algorithm for bankruptcy forecasting. *Expert Systems with Applications*, 88, 393–401. <https://doi.org/10.1016/j.eswa.2017.07.025>.
 75. Zhang, G., Hu, M. Y., Patuwo, B E. a Indro, D.C., 1999. Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. *European Journal of Operational Research*, 116, (1), pp. 16-32, ISSN 0377-2217, [https://doi.org/10.1016/S0377-2217\(98\)00051-4](https://doi.org/10.1016/S0377-2217(98)00051-4).
 76. Zibanezhad, E., Foroghi, D. a Monadjemi, A. 2011. "Applying decision tree to predict bankruptcy". *IEEE International Conference on Computer Science and Automation Engineering*, Shanghai, China, pp. 165-169, doi: 10.1109/CSAE.2011.5952826.
 77. Zhou, L. a Lai, K. K., 2016. AdaBoost models for corporate bankruptcy prediction with missing data. *Computational Economics*, 50(1), 69-94. <https://doi.org/10.1007/s10614-016-9581-4>.
 78. Zhu, N., Zhu, C. a Emrouznejad, A., 2021. A combined machine learning algorithms and DEA method for measuring and predicting the efficiency of Chinese manufacturing listed companies. *Journal of Management Science and Engineering*. <https://doi.org/10.1016/j.jmse.2020.10.001>.
 79. Zmijewski, M., 1984. Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, 22, 59–82. <https://doi.org/10.2307/2490859>.