



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV EKONOMIKY

INSTITUTE OF ECONOMICS

MODELOVÁNÍ PREDIKCE ÚPADKU VE ZPRACOVATELSKÉM PRŮMYSLU

BANKRUPTCY PREDICTION MODELLING IN MANUFACTURING BRANCH

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Martina Kulkusová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Michal Karas, Ph.D.

BRNO 2019

Zadání diplomové práce

Ústav:	Ústav ekonomiky
Studentka:	Bc. Martina Kulkusová
Studijní program:	Ekonomika a management
Studijní obor:	Podnikové finance a obchod
Vedoucí práce:	Ing. Michal Karas, Ph.D.
Akademický rok:	2018/19

Ředitel ústavu Vám v souladu se zákonem č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a se Studijním a zkušebním řádem VUT v Brně zadává diplomovou práci s názvem:

Modelování predikce úpadku ve zpracovatelském průmyslu

Charakteristika problematiky úkolu:

Úvod

Cíl a metody zpracování práce

Teoretická východiska predikce bankrotu a popis testovaných modelů

Zhodnocení současné efektivnosti vybraných bankrotních modelů na zkoumaném vzorku podniků

Návrh vlastního bankrotního modelu

Srovnání efektivnosti vytvořeného modelu a vybraných modelů

Shrnutí

Závěr

Seznam použité literatury

Přílohy

Cíle, kterých má být dosaženo:

Cílem práce je zhodnotit rozlišovací schopnost (predikční přesnost) pěti vybraných bankrotních modelů na datech podniků zpracovatelského průmyslu ČR a její porovnání s původně deklarovanou přesností. Studentka metodou logistické regrese odvodí vlastní model a provede testování jeho rozlišovací schopnosti.

Základní literární prameny:

ALAMINOS D. and A. DEL CASTILLO, M. Á. FERNÁNDEZ. Correction: A Global Model for Bankruptcy Prediction. PLOS ONE, vol. 13, no. 11: e0166693. ISSN 1932-6203

BHANDARI, S and A. J. JOHNSON-SYDER. A Generic Model Of Predicting Probability Of Success-Distress Of An Organization: A Logistic Regression Analysis. Journal of Applied Business Research. 2018, vol. 34, no. 1, pp. 169-182. ISSN 0892-7626.

BREZIGAR-MASTEN, A, and I. MASTEN. CART-based selection of bankruptcy predictors for the logit model. Expert Systems With Applications. 2012, vol. 39, no. 11, pp. 10153-10159. ISSN 0957-4174.

GRICE, J. S. and M. T. DUGAN. The limitations of bankruptcy prediction models: Some cautions for the researchers. Review of Quantitative Finance and Accounting. 2001, vol. 17, pp. 151-166. ISSN 1573-7179.

PREMACHANDRA, I. M. and G. S. BHABRA, T. SUEYOSHI. DEA as a tool for bankruptcy assessment: A comparative study with logistic regression technique. European Journal of Operational Research. 2009, vol. 193, no. 2, pp. 412-424. ISSN 0377-2217.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2018/19

V Brně dne 28.2.2019

L. S.

doc. Ing. Tomáš Meluzín, Ph.D.
ředitel

doc. Ing. et Ing. Stanislav Škapa, Ph.D.
děkan

Abstrakt

Tato diplomová práce se zabývá problematikou predikce bankrotu společností působících ve zpracovatelském průmyslu v České republice. V teoretické části práce jsou definovány pojmy související s tématem predikce bankrotu, metody tvorby bankrotních modelů a výběru proměnných a vybrané bankrotní modely. Analytická část práce zahrnuje testování vybraných bankrotních modelů. Dále je vytvořen nový bankrotní model, který je následně testován a jeho přesnost je porovnávána s modely od jiných autorů.

Abstract

The diploma thesis is aimed at the problematic within the prediction of bankruptcy of companies operating in manufacturing industry in Czech Republic. There are defined terms related to the topic, methods of creating bankruptcy models and selected bankruptcy models in the theoretical part. Analytical part includes testing of the selected bankruptcy models. Thereafter a new bankruptcy model is created, which is subsequently tested and its accuracy is compared to models from other authors.

Klíčová slova

Bankrot, úpadek, bankrotní model, predikce bankrotu, finanční zdraví, finanční tíseň, ROC křivka

Key words

Bankruptcy, insolvency, bankruptcy prediction model, bankruptcy prediction, financial health, financial distress, ROC curve

Bibliografická citace

KULKUSOVÁ, Martina. *Modelování predikce úpadku ve zpracovatelském průmyslu* [online]. Brno, 2019 [cit. 2019-05-09]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/119966>. Diplomová práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav ekonomiky. Vedoucí práce Michal Karas.

Čestné prohlášení

Prohlašuji, že předložená diplomová práce je původní a zpracovala jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušila autorská práva (ve smyslu Zákona č. 121/2000 Sb., o právu autorském a o právech souvisejících s právem autorským).

V Brně dne 10. května 2019

podpis studenta

Poděkování

Tímto bych ráda vyjádřila vděk vedoucímu mé diplomové práce, panu Ing. Michalovi Karasovi, Ph.D. za trpělivost a odborné vedení při tvorbě diplomové práce a za cenné rady, díky kterým jsem tuto práci mohla úspěšně dovést do zdárného konce.

OBSAH

ÚVOD.....	11
1 CÍL A METODIKA PRÁCE.....	12
1.1 Cíl práce	12
1.2 Použité metody.....	12
2 TEORETICKÁ VÝCHODISKA PREDIKCE BANKROTU A POPIS TESTOVANÝCH MODELŮ.....	14
2.1 Bankrot.....	14
2.1.1 Vymezení pojmu bankrot.....	14
2.1.2 Způsoby řešení úpadku	15
2.2 Bankrotní model.....	16
2.2.1 Vymezení pojmu bankrotní model	16
2.2.2 Historie bankrotních modelů	16
2.2.3 Současnost	17
2.3 Finanční zdraví.....	18
2.4 Finanční tíseň	19
2.5 Predikce bankrotu.....	20
2.6 Metody tvorby bankrotních modelů a výběru proměnných.....	21
2.6.1 Vícenásobná diskriminační analýza.....	22
2.6.2 Logistická regrese	23
2.6.3 Analýza hlavních komponent (PCA).....	24

2.6.4	Risk index modely	24
2.6.5	Ostatní metody	25
2.7	Vybrané bankrotní modely	26
2.7.1	Generický model	26
2.7.2	Slefendorfas model	27
2.7.3	Brezigar-Masten, Masten model	29
2.7.4	Globální bankrotní model	30
2.7.5	Beerman model	32
2.8	Způsob hodnocení bankrotních modelů	33
2.8.1	ROC křivky	33
2.8.2	Omezení modelů	36
3	ZHODNOCENÍ SOUČASNÉ EFEKTIVNOSTI VYBRANÝCH BANKROTNÍCH MODELŮ	38
3.1	Přesnost Generického modelu	38
3.2	Přesnost Slefendorfasova modelu	41
3.3	Přesnost Brezigar-Masten, Masten modelu	44
3.4	Přesnost Globálního bankrotního modelu	47
3.5	Přesnost Beermanova modelu	50
3.6	ROC křivky vybraných bankrotních modelů	53
3.7	T-test proměnných vybraných bankrotních modelů	58
4	NÁVRH VLASTNÍHO BANKROTNÍHO MODELU	61

4.1	Tvorba vlastního modelu.....	61
4.2	Přesnost modelu na trénovacím vzorku dat	67
4.3	Přesnost modelu na testovacím vzorku dat	69
4.4	Srovnání přesností trénovacího a testovacího vzorku dat	71
4.5	ROC křivky sestaveného modelu.....	72
5	SROVNÁNÍ EFEKTIVNOSTI VYTVOŘENÉHO MODELU A VYBRANÝCH MODELŮ	74
	ZÁVĚR	76
	SEZNAM POUŽITÝCH ZDROJŮ	78
	SEZNAM ZKRATEK	82
	SEZNAM TABULEK	83
	SEZNAM GRAFŮ	86
	SEZNAM PŘÍLOH.....	88

ÚVOD

Během životního cyklu každé společnosti dochází ke střídání několika fází. Jednou z těchto fází je také fáze krize. Některým společnostem se tuto fázi podaří překonat, v jiných dochází k bankrotu.

Nástroje, které pomáhají k odhalení nepříznivé hospodářské situace ve společnosti a slouží jako výstraha před hrozícím bankrotem, jsou bankrotní modely. V minulosti bylo vytvořeno velké množství modelů předpovídající bankrot podniku. Spousta z těchto modelů byla vytvořena v zahraničí a k jejich sestavení byla využita tehdejší data. Přesnost těchto modelů výrazně klesá v případě, že jsou použity např. v jiném státě, odvětví nebo oboru.

Teoretická část této práce se zaměřuje na definování stěžejních pojmů v oblasti predikce bankrotu, které jsou následně používány v celé práci. Dále charakterizuje metody tvorby bankrotních modelů a výběru proměnných. Následně je popsáno pět vybraných bankrotních modelů, konkrétně Generický model od autorů Bhandari a Johnson-Snyder, Slefendorfas model, Brezingar-Masten, Masten model, Globální bankrotní model a Beerman model. Další část teoretické práce se zabývá způsobem testování bankrotních modelů, které obsahují přesnost modelů, ROC křivky a omezení modelů.

Další část práce se zaměřuje na zhodnocení současné efektivnosti vybraných modelů. Zmíněné bankrotní modely budou testovány na datech pocházejících z oblasti zpracovatelského průmyslu v České republice. Bude vyhodnocena jejich přesnost, ROC křivky a významnost jednotlivých ukazatelů. Na základě toho a za pomoci logit analýzy bude následně vytvořen vlastní model.

1 CÍL A METODIKA PRÁCE

Tato část se zaměřuje na formulaci cíle této diplomové práce a definování vybraných metod, které byly použity při jejím zpracování.

1.1 Cíl práce

Cílem diplomové práce je zhodnotit predikční přesnost pěti vybraných bankrotních modelů v oblasti zpracovatelského průmyslu v ČR a její porovnání s původně deklarovanými přesnostmi. Pomocí logistické regrese bude následně sestaven vlastní model a bude provedeno testování jeho predikční schopnosti na vybraném vzorku podniků.

1.2 Použité metody

V této diplomové práci byly použity následující metody:

Literární rešerše

Metoda literární rešerše je využita především v teoretické části práce, která vychází z odborné literatury a zaměřuje se na danou problematiku modelování predikce bankrotu.

Analýza

Další metodou je analýza, která je jak součástí teoretické části práce, tak zároveň hraje důležitou roli v praktické části u testování jednotlivých bankrotních modelů. Je využita pro rozbor jednotlivých modelů a jejich zkoumání.

Syntéza

Metoda syntézy hraje důležitou roli při samotném sestavování modelu a zkoumání vzájemné korelace mezi jednotlivými proměnnými.

Klasifikace

Tato metoda byla využita při rozdělování jednotlivých společností do skupiny bankrotních nebo aktivních podniků.

Komparace

Metoda komparace nebo také srovnávání je využita při vzájemném porovnávání vybraných modelů a jejich původních a testovaných přesností.

Matematické a statistické metody

V případě této metody se jedná o využití logistické regrese při sestavování nového bankrotního modelu., dále použití t-testu a ROC křivek v případě testování významnosti jednotlivých modelů a také testování vzájemné korelace mezi jednotlivými ukazateli.

Modelování

Metoda modelování je využita při samotném návrhu a vytvoření nového bankrotního modelu.

2 TEORETICKÁ VÝCHODISKA PREDIKCE BANKROTU A POPIS TESTOVANÝCH MODELŮ

Teoretické část této diplomové práce se zaměřuje na definování pojmů, které se pojí s problematikou predikce bankrotu. Dále charakterizuje metody tvorby bankrotních modelů a výběru proměnných, popisuje pět vybraných bankrotních modelů a zabývá se způsobem testování bankrotních modelů.

2.1 Bankrot

Cílem této kapitoly je vymezení pojmu bankrot a dalších výrazů s ním souvisejících, poskytnutí informací spojených s bankrotem a definování možných způsobů jeho řešení.

2.1.1 Vymezení pojmu bankrot

Pojem bankrot je spojován s finančními problémy a platební neschopností dlužníka. V insolvenčním zákoně pojem bankrot však nenalezneme. Tento pojem je považován za jistou formu úpadku, který je definován jako neschopnost dlužníka platit své závazky vůči věřitelům (Insolvenční zákon, 2006).

V zahraniční literatuře se s pojmem bankrot pojí další výrazy, jako je např. „failure“, „insolvency“, „default“, „bankruptcy“ a „financial distress“. První z těchto pojmů tedy „failure“ říká, že dosažená míra návratnosti investovaného kapitálu je značně a trvale nižší než převládající míra podobných investic. Beaver (1966) definoval tento pojem také jako neschopnost firmy platit svoje závazky s jejich vývojem. Výraz „insolvency“ neboli platební neschopnost představuje problémy s likviditou a značí zápornou čistou hodnotu. Celková pasiva v tomto případě převyšují celková aktiva společnosti. Termín „default“ poukazuje na porušování podmínek smlouvy s věřitelem a možnost žaloby. Další pojem „bankruptcy“ vyjadřuje čistou hodnotu společnosti nebo soudní rozhodnutí, které vede k její likvidaci nebo reorganizaci. Poslední z těchto pojmů je „financial distress“. Tento pojem vyjadřuje neschopnost firmy platit své dluhy v době jejich splatnosti. Tuto situaci může ještě zhoršit skutečnost, že hodnota majetku společnosti je nižší než hodnota závazků (Zopounidis, 1998; Becerra, 2005)

Český zákon o insolvenční ve spojitosti s bankrotem využívá pojem úpadek. Dlužník se nachází v úpadku nebo platební neschopnosti tehdy, pokud má více věřitelů a finanční závazky po dobu delší třiceti dnů po lhůtě splatnosti a není schopen tyto závazky plnit. Dále není dlužník schopen plnit své finanční závazky, jsou-li zataveny platby podstatné části těchto závazků nebo nelze vyhovět některé z pohledávek výkonem rozhodnutí nebo exekucí. Úpadek lze vymezit také v tom případě, pokud dlužník nepředložil seznamy, které po něm požadoval insolvenční soud. Dalším důvodem úpadku může být tzv. předlužení. K předlužení dochází tehdy, pokud má dlužník více věřitelů a jeho celkové závazky převyšují hodnotu jeho majetku (Insolvenční zákon, 2006).

Pokud ve firmě dojde k úpadku, přečerpání jejího bankovního účtu, nedodržení závazku nebo neplacení dividend, jsou tyto události považovány za její selhání (Beaver, 1966).

2.1.2 Způsoby řešení úpadku

Mezi možné způsoby řešení úpadku se řadí konkurs, reorganizace, oddlužení nebo jiný zvláštní způsob řešení pro daný subjekt nebo situaci stanovený insolvenčním zákonem.

Konkurs je definován jako jeden ze způsobů řešení úpadku, který spočívá v uspokojení zjištěných pohledávek věřitelů z výnosu zpeněžení majetkové podstaty. Pokud není zákonem stanoveno jinak, neuspokojené pohledávky ani jejich části nezanikají (Insolvenční zákon, 2006).

U reorganizace zní definice insolvenčního zákona následovně: „*Reorganizací se rozumí postupné uspokojování pohledávek věřitelů při zachování provozu dlužníkovy podniku, zajištěné opatřeními k ozdravení hospodaření tohoto podniku podle insolvenčním soudem schváleného reorganizačního plánu s průběžnou kontrolou jeho plnění ze strany věřitelů.*“ (Insolvenční zákon, 2006)

K oddlužení může dojít v případě, že dlužníkem je buďto právnická osoba, jež není považována za podnikatele a nedisponuje dluhy z podnikání, nebo fyzická osoba, která rovněž nemá dluhy z podnikání (Insolvenční zákon, 2006).

2.2 Bankrotní model

Tato kapitola se zaměřuje na definování bankrotních modelů a jejich historii.

2.2.1 Vymezení pojmu bankrotní model

Bankrotní modely řadíme do kategorie soustav účelově vybraných ukazatelů. Jejich cílem je posouzení finančního zdraví firmy pomocí jedné číselné charakteristiky. Podávají informace o tom, jestli je společnost v dohledné době ohrožena bankrotem. Opírají se o skutečnost, že každá firma, která je ohrožena bankrotem, se před jeho proděláním vyznačuje symptomy, které jsou pro tuto situaci typické (Růčková, 2011).

2.2.2 Historie bankrotních modelů

První kdo se zabýval studiem bankrotu firem, byl Fitzpatrick v roce 1932. Na základě srovnání dvaceti firem v jeho studii zjistil, že zdravá firma se od firmy ve finanční tísní odlišuje především hodnotami likvidity, velikostí dluhu a obratu.

Dalšími, kdo studovali finanční ukazatele, byli Smith a Winakor v roce 1935. Jejich studie obsahovala data ze 183 firem.

Chudson přišel v roce 1945 se studií, která říká, že je vhodnější vytvořit různé bankrotní modely pro jednotlivá odvětví.

V roce 1966, Beaver zjistil, že při rozlišování finančně zdravé firmy od firmy, jež hrozí bankrot, je významných 30 finančních ukazatelů. Přesnost jeho bankrotního modelu byla 90 %, a to rok před bankrotem daných firem. Jeho studie byla založená na jednorozměrné diskriminační analýze. Jako vzorek mu posloužilo 79 párů společností.

Altman jako první přišel s vícerozměrným statistickým modelem v roce 1968. Zastával názor, že jednorozměrné modely nejsou pro určení bankrotu dostatečné. Pro jeho studii využil 33 bankrotních a 33 bankrotem neohrožených firem. Altmanův model se skládá z pěti finančních ukazatelů a jeho přesnost dosahuje 95 %. Pro studii použil vícerozměrnou diskriminační analýzu. Později Altman vytvořil další model zvaný ZETA. V tomto případě zkoumal Altman 58 párů firem. Oproti předchozímu modelu tento

obsahoval o jeden finanční ukazatel více. Jeho přesnost se uvádí ve výši 96 %. Tento model se pro predikci bankrotu používá do současnosti.

Následně po Altmanovi vzniklo několik dalších bankrotních modelů. Zmínit můžeme např. Deakina (1972), Bluma (1974), Springata (1978) a Fulmera (1984).

Ohlson použil data nashromážděná od roku 1970 do roku 1976. Tato data pocházela ze 105 bankrotních a 2 058 finančně stabilních firem. Ohlson jako první použil logistickou regresní analýzu a poukázal na negativní vztah ve velikosti firem. Jeho model je unikátní v tom, že nebere v úvahu to, co předpovídá vícerozměrná diskriminační analýza, jejíž slabou stránkou je, že neudává pravděpodobnost bankrotu.

Zmijewski v roce 1984 použil ve svém výzkumu probitovou regresi. Ve své studii čerpal data ze 40 bankrotních a 800 zdravých firem.

Postupem času se množství studií a bankrotních modelů zvyšovalo. Napomohlo k tomu objevení probitové (= probit) a logistické (= logit) regrese. Obsahem spousty z těchto studií bylo srovnávání logistické regrese s vícerozměrnou diskriminační analýzou. Hlavní myšlenkou bylo zjistit, který model je přesnější.

Během devadesátých let 20. století došlo k velkému vývoji informačních technologií, což napomohlo vzniku analýzy neuronové sítě. Jedná se o neparametrické modelování. Tuto metodu ve svých studiích použili např. Messier a Hansen (1988), Raghupathi (1991), Coats and Fant (1993), Guan (1993) a další (Fejér-Király, 2015).

2.2.3 Současnost

S postupem času a vývojem technologií začaly vznikat modernější metody sloužící k predikci bankrotu. Za jednu z nich můžeme považovat tzv. hybridní modely. Podstatou tohoto modelování je spojení dvou různých modelů. Mezi další neparametrické modelování řadíme např. genetické programování, modelování založené na „rough testu“, analýzu obálek dat a další. Při vznikání nových modelů se jejich autoři snažili o co největší přesnost.

Po roce 2005 se začaly prosazovat modely založené na umělé inteligenci. Jako příklad můžeme uvést studii od Premachandra z roku 2009, kde srovnával analýzu obalu dat

a logistickou regresi. Zjistil, že analýza obálek dat je přesnější v případě určení bankrotu s přesností 84-89 %, a naopak logistická regrese dosahuje vyšší přesnosti (69,3 - 99,47 %) u předpovídání zdravých firem (Premachandra, 2009).

S dalším novým přístupem přišli v roce 2011 Korol a Korodi, kteří k predikci bankrotu využili tzv. fuzzy logiku. Pro jejich studii využili data ze 132 společností. Provedli srovnání dvou modelů, jež každý z nich byl založen na jiných finančních ukazatelích. U jednoho z těchto modelů dosahovala přesnost 88,9 % (Korol, Korodi, 2011).

Mezi další moderní metody modelování predikce bankrotu můžeme zařadit modelování rizik. Tuto metodu využil Gupta společně s jeho kolegy v jejich výzkumu v roce 2014. Použili data ze 385 733 zdravých a 8 162 bankrotních firem. Vyvinuli tři modely rizik pro mikro, malé a středně velké podniky. Tyto modely dosahovaly přesnosti mezi 74,14 % a 76,10 % (Fejér-Király, 2015).

2.3 Finanční zdraví

Bankrotní modely jsou obecně považovány za nástroj hodnocení finančního zdraví podniku. Na finanční zdraví nebo také stabilitu se nahlíží jako na základní předpoklad existence každé společnosti. Základní kritéria, která ovlivňují finanční zdraví podniku, jsou následující:

- struktura finančních zdrojů společnosti,
- likvidita,
- solventnost,
- schopnost adaptability,
- ekonomické zdroje,
- schopnost tvorby zisku,
- schopnost maximalizace tržní hodnoty (Kaplinski, 2008).

Interní subjekty společnosti disponují všemi potřebnými informacemi potřebnými k posouzení jejího finančního zdraví. Přehled o stavu finančního zdraví však nepředstavuje významný ukazatel pouze pro společnost samotnou. Tyto informace hrají významnou roli také pro externí subjekty, které se společností přichází do obchodního

kontaktu nebo jsou jejich vztahy jinak vzájemně provázány. Za tyto subjekty jsou nejčastěji považováni zákazníci, dodavatelé, stát nebo finanční instituce (Čámská, 2012).

2.4 Finanční tíseň

Pro pojem finanční tíseň neexistuje jednoznačná definice. Jedná se však o podnikové selhání. Je možné ji charakterizovat jako vykazování ztráty a prodej podílů soukromým investorům, několikaleté vytváření kumulovaných ztrát nebo negativních akcionářských fondů, vstup do fáze reorganizace atd. Obecně lze konstatovat, že společnost, která se nachází ve finanční tísní, vykazuje alespoň jednu z následujících vlastností:

- záporné čisté provozní výnosy v období několika let,
- přerušení výplaty dividend,
- zásadní restrukturalizace nebo propouštění (Vochozka, 2011).

„Finanční tíseň nastává tehdy, když jsou problémy s platební schopností tak vážné, že nemohou být vyřešeny bez výrazných změn v provozní a/nebo finanční činnosti podniku.“ (Grünwald, Holečková, 2009)

Finanční tíseň označuje ohrožení existence podniku. Jako důvody vzniku tohoto ohrožení mohou být označeny např. předluženost, platební neschopnost, snižování vlastního kapitálu a další. Tuto nepříznivou situaci lze pomocí použití vybraných ukazatelů finanční analýzy předpovídat. Smejkal a Rais uvádí, že jednou z možností předpovědi finanční tísně je sledování následujících ukazatelů:

- cizí zdroje / cash flow,
- zisk po zdanění / aktiva celkem,
- krátkodobý bankovní úvěr / cizí zdroje,
- cizí zdroje / aktiva celkem,
- pracovní kapitál / zásoby,
- oběžná aktiva / krátkodobé cizí zdroje (Smejkal, Rais, 2013).

S finanční tísní se také pojí náklady finanční tísně, které zahrnují dvě základní kategorie - náklady úpadku a náklady plynoucí z konfliktu zájmů mezi majiteli akcií a věřiteli

či manažery. Náklady úpadku označují náklady, které musí podnik hradit v případě, že důvodem jeho úpadku jsou finanční obtíže. Jedná se např. o poplatky právníkům, pokles tržní ceny majetku, nárůst požadované výnosnosti věřitelů a investorů a další. Náklady vyplývající z konfliktu zájmů mezi majiteli akcií a věřiteli či manažery vznikají v důsledku přenechání řízení podniku vlastníky akcií jiným osobám (agentům) s odlišnými zájmy (Nývtová, Marinič, 2010).

2.5 Predikce bankrotu

Na každého, kdo je v určitém vztahu k nějaké společnosti, ať už jako zaměstnanec, vlastník nebo např. investor, má bankrot negativní dopad. V případě zaměstnance to znamená ztrátu zaměstnání. V zájmu každého stakeholdera je tedy bankrotu firmy předcházet (Fejér-Király, 2015).

Některé společnosti se dostanou do nepříznivé finanční situace a setrvávají v ní po mnoho let, než nakonec dojde k jejich selhání. V jiném případě dojde k bankrotu firmy okamžitě. Tyto situace jsou ovlivňovány několika faktory, kterými jsou např. audit, podvody, počáteční fáze firmy a stresové události, které jsou měřeny pomocí kvantitativních nebo kvalitativních proměnných (Tsai, 2009).

Klíčovým aspektem pro zabránění bankrotu je včasné zaznamenání jeho příznaků, následná reakce a způsob řešení. Pokud jsou příznaky zaznamenány včas, je možné se před nimi bránit. Je definováno osm kroků, které vedou k úpadku, a měly by pro společnost představovat varovné signály.

- 1) Klesá výroba a prodej, což následně vede i poklesu tržeb a zisku po zdanění.
- 2) Klesá obrát zásob materiálu a výrobků. Vzniká snaha získat další zakázky a snižuje se tak obezřetnost v oblasti výběru odběratelů – vznik nedobytných pohledávek.
- 3) Objevují se finanční potíže. Podnik není schopen emitovat akcie a dluhopisy, získat úvěr za výhodných podmínek a vyplácet dividendy. Dochází k čerpání finančních rezerv.
- 4) Kvůli nedostatku financí dochází ke zpomalování investic zahájených v minulých obdobích. Aktivita klesá, zadluženost se zvyšuje.

- 5) Na základě nedostatečných příjmů dochází k platebním problémům, čímž se zvyšuje doba splácení závazků.
- 6) Majetek nabývá nižší hodnoty než dluhy, což značí předlužení podniku, které může být důvodem k vyhlášení úpadku.
- 7) Zvyšuje se nátlak věřitelů na uhrazení závazků.
- 8) Společnost se nachází v platební neschopnosti a následně vyhlásí úpadek (Grünwald, Holečková, 2009).

Vývoj predikce bankrotu v čase je přisuzován následujícím důvodům (Fejér-Király, 2015):

- 1) V případě, že společnost postihne bankrot, jsou stakeholdeři nuceni vynaložit vysoké náklady. Důvodem je tedy snaha snížit zmíněné náklady.
- 2) Díky negativním ekonomickým trendům se firmy staly více zranitelnými a náchylnějšími k bankrotu.
- 3) Byly zveřejněny finanční informace o firmách.
- 4) Začaly se objevovat informace o nedokonalosti trhu a informační asymetrii.
- 5) Rostla potřeba tvorby kvalitnějších reportů o finančním zdraví firem.
- 6) K tvorbě nových bankrotních modelů přispěla také snaha o optimální rozdělení kapitálu.

2.6 Metody tvorby bankrotních modelů a výběru proměnných

Predikce bankrotu je považována za klasifikační problém. Na základě vstupních proměnných, které zahrnují finanční a účetní data, je třeba rozlišit, zda se jedná o bankrotující nebo nebankrotující společnost (Tsai, 2009).

Metody předpovědi vývoje finanční situace společnosti slouží k přiřazení daného podniku buďto do kategorie zdravých nebo bankrotních podniků. Pomocí jednoho čísla, které je výstupem bankrotního modelu, je společnost následně srovnávána s ostatními subjekty. K tomuto účelu existuje několik metod tvorby bankrotních modelů, které se využívají v praxi (Vochozka, 2011).

Ve většině studií je využíváno velké množství proměnných, které jsou často vybírány na základě jejich popularity nebo osvědčenosti z předchozích studií. Mezi další způsoby výběru proměnných lze zařadit např. statistické úvahy, teoretické modely nebo kombinaci empirických metod s teoretickými modely. Finální soubor proměnných, který tvoří výsledný model predikce bankrotu, je většinou vybírán tak, aby vytvořil co nejlepší model pro vybraný vzorek. Tento soubor je většinou zvolen na základě statistických postupů (Vochozka, 2011).

Mezi nejčastěji používané metody tvorby bankrotních modelů a výběru proměnných lze zařadit např. vícenásobnou diskriminační analýzu (MDA), logistickou regresi (logit), analýzu hlavních komponent (PCA), risk index modely a další metody.

2.6.1 Vícenásobná diskriminační analýza

Vícenásobná diskriminační analýza neboli MDA (Multiple diskriminant analysis) označuje statistickou metodu, která využívá klasifikaci jednotlivých veličin do vybraných skupin na základě charakteristických vlastností daných veličin. Následně se pomocí MDA odvozuje lineární kombinace veličin, které jsou pro rozdělení do jednotlivých skupin nejvhodnější. MDA je definována lineárními kombinacemi proměnných, které nejlépe rozlišují prosperující a bankrotující subjekty (Vochozka, 2011).

U MDA se využívá kombinace různých finančních ukazatelů s vybranými proměnnými, což následně vytvoří vícerozměrné diskriminační skóre. Výsledek diskriminačního skóre je definován jako jednorozměrová kalkulace stanovující představu o finančním zdraví podniku. Smyslem metody je přiřadit subjektu status zdravé nebo bankrotující společnosti na základě diskriminačního skóre (Vochozka, 2011).

Pro stanovení klasifikační spolehlivosti metody MDA se často využívá procento správných klasifikací nebo nevážené chybovosti podle typu I a II. Dalším způsobem posouzení přesnosti je např. pomocí ROC křivek. Čím větší je plocha pod křivkou, tím vyšší je spolehlivost daného modelu (Vochozka, 2011).

Využití metody MDA je založeno na následujících předpokladech:

- „nezávislé proměnné zahrnuté do modelu ze statistického hlediska odpovídají vícerozměrnému rozdělení pravděpodobností,
- skupiny matice rozptylu nebo matice závislosti jsou mezi skupinami upadajících a prosperujících společností shodné,
- náklady chybné klasifikace jsou známé.“ (Vochozka, 2011)

Ač se jedná o nejčastěji používanou metodu, MDA má také značné nevýhody nebo nebývá aplikována nevhodným způsobem. Data, která jsou v praxi využívána, mnohdy nesplňují výše zmíněné předpoklady, přesto je metoda aplikována a výsledky jsou tak minimálně diskutabilní. Metoda vyžaduje lineárnost klasifikačního pravidla, což znamená, že dobré nebo špatné finanční zdraví je definováno na základě toho, zda se výsledné skóre nachází nad nebo pod určitým mezním bodem. Dále je nutné si uvědomit, že výsledky MDA značí pouze pořadová měření umožňující řadové hodnocení mezi jednotlivými subjekty. MDA koeficienty neuvažují interní korelace mezi proměnnými v rámci daného modelu a jsou nejednoznačné (Vochozka, 2011).

2.6.2 Logistická regrese

Logistická regrese představuje univerzální metodu, která umožňuje určit vliv nominálních nebo spojitých faktorů na dichotomický nominální výsledek. Cílem metody logistické regrese je vytvořit nejvhodnější a nejdokonalejší model, který popisuje vztah mezi výslednou proměnnou a množinou nezávislých proměnných (Hosmer, 2000).

Vytváří regresní rovnici, která slouží jako prostředek k predikci pravděpodobnosti zařazení subjektu do skupiny zdravých nebo bankrotních podniků na základě přihlédnutí k jedné nebo více charakteristikám. Hraničním bodem pro tuto pravděpodobnost je 0,5. V případě, že se výsledek blíží hraničnímu bodu, je nutné uvažovat vysokou náchylnost k chybám. Čím více se výsledek blíží 0 nebo 1, tím je považován za důvěryhodnější (Rowe, 2015).

Nevýhodou této metody je např. extrémní citlivost na problém vícenásobné závislosti, což vyžaduje vyvarování se využití vysoce závislých proměnných. Problémem je, že metoda je většinou založena především na finančních poměrových ukazatelích, které

spolu úzce souvisí. Dalším úskalím pro metodu logistické regrese je citlivost na nesourodé hodnoty, tedy hodnoty pocházející z nesourodých měření nebo chybějící hodnoty (Vochozka, 2011).

2.6.3 Analýza hlavních komponent (PCA)

Cílem analýzy hlavních komponent neboli PCA (Principal Component Analysis) je snížit počet proměnných popisujících určitou skupinu a vytvořit menší počet komponent, které jsou vzájemně nezávislé. Uspořádání hlavních komponent je závislé na skutečnosti, kolik variability původní množiny proměnných vysvětlují. Z toho plyne, že na první pozici stojí hlavní proměnná, která objasňuje největší část dané variability. Aby PCA mohla zkoumat jiné vlastnosti dat pomocí jednotlivých proměnných, zaměřuje se také na jejich korelaci a snaží se vytvořit nové proměnné, které nejsou korelované. Nově vzniklé proměnné jsou pak označovány jako hlavní komponenty (Hendl, 2012).

Nově vzniklé hlavní proměnné mají vhodnější vlastnosti pro jejich další zpracování oproti původním proměnným. Přesto, že jich je menší počet, dokáží vystihnout téměř celou proměnlivost původních proměnných (Janiček, Marek, 2013).

Pro určení vhodnosti dat využívaných při analýze hlavních komponent se používá tzv. KMO (Kaiser, Meyer, Olkin) míra. Tato statistická míra nabývá intervalových hodnot [0;1]. Hodnota 0 znamená absenci vztahu mezi jednotlivými proměnnými a hodnota 1 naopak představuje výskyt významného vztahu proměnných. Výpočet KMO míry je založen na korelačních a parciálních koeficientech. Doporučená hodnota KMO míry by měla odpovídat minimálně 0,6 (Robu, Istrate, 2015).

2.6.4 Risk index modely

Risk index modely patří mezi metody, které k posouzení finančního zdraví používají více než jednu proměnnou. Tamari (1966) označil jeho risk index jako jednoduchý „bodový systém“ zahrnující několik poměrových ukazatelů, které jsou akceptovány jako ukazatele hodnotící finanční zdraví společnosti. Vzhledem k výsledkům daných ukazatelů jsou společnostem následně přidělovány body na škále 0-100. Čím více je dané společnosti přiděleno, tím je její finanční situace považována za lepší. Jednotlivé ukazatele mají také přiděleny váhy, které definují jejich významnost (Vochozka, 2011).

Dalším příkladem risk indexu je model od autorů Moses a Liao (1987). Tito autoři využili pro sestavení modelu jednorozměrnou analýzu, která určuje mezní body jednotlivým poměrovým ukazatelům. Každý poměrový ukazatel má přiděleny bipolární proměnné. Každá tato proměnná dosahuje 1 bodu v případě, že přesáhne mezní hranici. V opačném případě dosahuje hodnoty 0. Sestavení modelu je poté založeno na přidání bipolárních proměnných. Stejně jako u předchozího modelu označuje vyšší hodnota lepší finanční zdraví společnosti (Vochozka, 2011).

Risk index modely jsou ve většině případů snadno aplikovatelné a intuitivní. Je však nutné si uvědomit, že chování tohoto ukazatele může být mnohdy spíše subjektivní. Otázkou proto zůstává, zda se jedná spíše o výhody nebo nevýhody těchto modelů (Vochozka, 2011).

2.6.5 Ostatní metody

Jako další metodu tvorby bankrotních modelů lze označit např. **jednorozměrnou analýzu**. U této metody je hodnocení prováděno pro každou hodnotu nebo ukazatel samostatně. Na základě optimálního hraničního bodu ukazatele je společnost následně zařazena mezi bankrotní nebo nebankrotní (Vochozka, 2011). Mezi jednorozměrné metody lze zařadit např. **T-test**. Tato metoda určuje existenci významného rozdílu středních hodnot mezi dvěma skupinami dat. Přináší odpověď na otázku, zda obě skupiny dat pocházejí ze stejné populace a zda jsou vyzorované rozdíly pouze náhodné nebo mají vyšší význam (Tsai, 2009).

Využití t-testu se nachází v predikci bankrotu u testování vlivu a jeho významu u finančních ukazatelů na skupiny zdravých a upadajících podniků (Zanganeh, 2011).

Kromě metod zmíněných výše lze také mezi metody vycházející z regrese zařadit tzv. **postupnou regresi**. Tato metoda slouží k nalezení optimální podmnožiny prediktorů z původní velké množiny případných prediktorů. Cílem postupné regrese je nalézt nejlepší proměnnou a následně k ní přidávat další proměnné se specifickými znaky. Tyto proměnné pak společně tvoří kombinaci proměnných s významnými korelačními koeficienty (Tsai, 2009).

Metoda, která se řadí mezi vícekritériální hodnocení, je označována jako **faktorová analýza**. Tato metoda považuje korelace za projev jistého nepozorovaného faktoru, který není přímo přístupný – stojí za pozorovanými proměnnými. Soubor těchto faktorů charakterizuje vybrané veličiny (Synek, Kopkáně, Kubálková, 2009).

2.7 Vybrané bankrotní modely

V této části práce budou představeny a popsány vybrané bankrotní modely od zahraničních autorů.

2.7.1 Generický model

Tento model patří mezi jeden z nejnovějších. Byl vytvořen dvěma autory (Shyam Bhandari, Anna J. Johnson-Snyder) na Bradleyho univerzitě v USA na začátku roku 2018. Jedná se o binární regresní model založený na proměnných získaných z výkazu cash flow. Tento model je obecný v tom smyslu, že může být použit k předpovědi pravděpodobnosti úspěchu každého subjektu, který používá tři hlavní finanční výkazy. Model byl vytvořen za použití logistické regrese (Bhandari, Johnson-Syder, 2018).

Jako vzorek bylo použito přibližně 90 neúspěšných firem z období 2008-2015. Každá firma byla následně srovnána s finančně zdravou firmou podobné velikosti.

Rovnice výpočtu:

$$Z_i = -2,636 + 3,093 X_1 + 0,263 X_2 + 7,306 X_3 + 2,020 X_4 + 0,108 X_5$$

Kde:

X_1 = *Provozní cash flow / krátkodobé závazky*

X_2 = *Úroky kryté z cash flow*

X_3 = *Provozní marže cash flow*

X_4 = *Rentabilita cash flow z celkových aktiv*

X_5 = *Kvalita zisku*

Hodnotu Z_i lze následovně převést na pravděpodobnost úspěchu nebo neúspěchu firmy pomocí následující rovnice.

$$p_i = \left(\frac{e^{z_i}}{1 + e^{z_i}} \right) \times 100$$

Výpočet proměnných:

$$X_2 = (\text{provozní cash flow} + \text{nákl. úroky} + \text{daň z příjmu}) / \text{nákl. úroky}$$

$$X_3 = \text{provozní cash flow} / \text{tržby}$$

$$X_4 = \text{provozní cash flow} / \text{aktiva celkem}$$

$$X_5 = \text{EBIT} / \text{provozní cash flow}$$

Model správně zařadil 70 z 81 zdravých firem, což odpovídá přesnosti 86,4 %, a 88 z 94 bankrotujících firem, kde je přesnost na úrovni 93,6 % (Bhandari, Johnson-Syder, 2018).

2.7.2 Slefendorfas model

Nejběžnějším typem podniku v Litvě jsou společnosti s ručením omezeným, které tvoří 62,3 % celkového počtu společností. Hlavním cílem studie proto bylo vytvořit model, který bude pro tyto společnosti nejpřesnější. Pro sestavení modelu byla použita vícerozměrná diskriminační analýza s finančními ukazateli a následně vytvořena lineární funkce ZGS (Slefendorfas, 2016).

Data byla čerpána ze 145 společností, z toho bylo 72 bankrotujících a 73 aktivních v období let 2007-2012.

Rovnice výpočtu:

$$\begin{aligned}
 Z_{GS} = & 1,739 + 1,45 \times \frac{\text{tržby}_t - \text{tržby}_{t-1}}{\text{tržby}_{t-1}} + \\
 & 0,922 \times \frac{\text{provozní náklady}_{t-3} - \text{provozní náklady}_{t-4}}{\text{provozní náklady}_{t-4}} + \\
 & 1,307 \times \frac{\text{provozní zisk}_t}{\text{tržby}_t} - 1,491 \times \frac{\text{celkové závazky}_{t-4}}{\text{aktiva celkem}_{t-4}} - 0,677 \times \frac{\text{čistý zisk}_{t-5}}{\text{vlastní kapitál}_{t-5}} + \\
 & 1,257 \times \frac{\frac{\text{aktiva celkem}_t}{\text{celkové závazky}_t} - \frac{\text{aktiva celkem}_{t-4}}{\text{celkové závazky}_{t-4}}}{\frac{\text{aktiva celkem}_{t-4}}{\text{celkové závazky}_{t-4}}} + \\
 & 0,1 \times \frac{\frac{\text{vlastní kapitál}_t}{\text{celkové závazky}_t} - \frac{\text{vlastní kapitál}_{t-2}}{\text{celkové závazky}_{t-2}}}{\frac{\text{vlastní kapitál}_{t-2}}{\text{celkové závazky}_{t-2}}} - \\
 & 0,344 \times \frac{\frac{\text{finanční a investiční náklady}_{t-2}}{\text{tržby}_{t-2}} - \frac{\text{finanční a investiční náklady}_{t-4}}{\text{tržby}_{t-4}}}{\frac{\text{finanční a investiční náklady}_{t-4}}{\text{tržby}_{t-4}}} - \\
 & 0,246 \times \frac{\frac{\text{provozní náklady}_{t-2}}{\text{tržby}_{t-2}} - \frac{\text{provozní náklady}_{t-5}}{\text{tržby}_{t-5}}}{\frac{\text{provozní náklady}_{t-5}}{\text{tržby}_{t-5}}}
 \end{aligned}$$

Kde:

Z_{GS} = koeficient predikce bankrotu pro období $t - 1$

t = současný rok

Ukazatele tržeb, celkových aktiv, celkových závazků a vlastního kapitálu mají největší dopad na celou funkci.

Je-li hodnota nižší než 0, je naznačována pravděpodobnost úpadku v následujícím roce. Pokud je hodnota koeficientu naopak vyšší než 0, znamená to, že společnost bude s největší pravděpodobností prosperovat (Slefendorfas, 2016).

Výsledky ukázaly, že přesnost vytvořeného modelu dosahuje hodnoty 89 % (Slefendorfas, 2016).

2.7.3 Brezigar-Masten, Masten model

Autoři této studie přišli s novým postupem výběru prediktorů založeným na metodě klasifikačních a regresních stromů a otestovali jejich výkonnost v rámci standardního logitového modelu. Tato studie byla vytvořena ve Slovinsku (Brezigar-Masten, Masten, 2012).

Bylo sestaveno několik verzí modelu s různými proměnnými a různou velikostí. Nejlepší výsledek byl získán za použití logit modelu s kategoričnými proměnnými na základě výsledku aplikace modelu CART (Brezigar-Masten, Masten, 2012).

Data pro tuto studii pochází ze dvou databází slovinských firem. Jednalo se o 39 005 zdravých firem a 592 firem v úpadku. Pro konečný model bylo využito 888 z nich. Data byla shromážděna za období 1995-2001 (Brezigar-Masten, Masten, 2012).

Vyjádření modelu je následující:

$$h(\theta'X) = \frac{e^{\theta'X}}{1+e^{\theta'X}}$$

Rovnice výpočtu:

$$\theta'X = -5.27 - 3.44 \cdot tfs + 0.07 \cdot pppo + 0.5 \cdot kol + 1.28 \cdot cf2d + 2.2 \cdot D1 + 2.56 \cdot D2$$

Kde:

tfs = celkové závazky/celková aktiva

pppo = provozní výnosy/provozní náklady

kol = celková aktiva/krátkodobé závazky

cf2d = cash flow/krátkodobé závazky

$D1 = 1$ když $ds > -0.038$; $= 0$ v opačném případě

$ds = EAT/celková aktiva$

$D2 = 1$ když $kd > 0.328$; $= 0$ v opačném případě

$kd = vlastní kapitál/celkové závazky$

2.7.4 Globální bankrotní model

Cílem studie španělských autorů Davida Alaminose, Agustína del Castillo, Manuela Ángel Fernández de bylo vytvořit globální model s dobrou schopností předpovědět bankrot v jakémkoliv regionu na světě (Alaminos, Castillo, 2018).

Pro tyto účely byly definovány následující hypotézy:

H1: *Proměnné pro predikci bankrotu v jednotlivých regionech jsou odlišené od proměnných v globálním modelu.*

H2: *Zavedení fiktivních regionálních proměnných zlepšuje prediktivní kapacity globálního modelu.*

H3: *Globální model je schopen správně předpovídat v různých regionech světa.*

Jako vzorek posloužila data 440 společností z 3 světových regionů: Asie (*Japonsko, Jižní Korea, Singapur a Tchaj-wan*), Evropa (*Rakousko, Dánsko, Francie, Německo, Irsko, Portugalsko, Španělsko, Švédsko, Švýcarsko a Spojené království*) a Amerika (*Bermudy, Kanada a Spojené státy*). Data byla získána za období 1990-2013 (Alaminos, Castillo, 2018).

V rámci studie bylo využito logit modelu založeného na finančních proměnných. Specifikace modelu je následující:

$$y_i^* = x_i + \varepsilon_i$$

$$y_i = \begin{cases} 1 & \text{if } y_i^* > 0,5 \\ 0 & \text{if } y_i^* \leq 0,5 \end{cases}$$

$$P[y_i = 1] = P[x_i\beta + \varepsilon_i > 0,5] = F(x_i\beta)$$

$$P[y_i = 0] = 1 - F(x_i\beta)$$

Kde:

y_i^* dosahuje hodnoty 1, jestliže se jedná o bankrotující firmu nebo hodnoty 0 v opačném případě.

Model byl odhadnut pomocí metody zpětných kroků, kde eliminace proměnných vychází z pravděpodobnosti statistických údajů o hodnověrnosti. Pokud je odhad pravděpodobnosti větší než 0,5, značí to pravděpodobnost úpadku společnosti, jinak se předpokládá, že náleží ke druhé zvažované skupině (Alaminos, Castillo, 2018).

Byly vytvořeny 3 verze modelu: globální, regionální a globální model s kategorickými regionálními proměnnými.

Pravděpodobnost bankrotu je definována následující rovnicí:

$$p_i = \left(\frac{e^{Y_{(GD)t-1}}}{1 + e^{Y_{(GD)t-1}}} \right)$$

Rovnice výpočtu:

$$Y_{(GD)t-1} = -2.695 + 6.635V3 - 18.292V5 + 4.759V9 + 0,713 \cdot Region$$

Kde:

V3 = pracovní kapitál / aktiva celkem

V5 = EBIT / aktiva celkem

V9 = oběžná aktiva / aktiva celkem

Region = kategorická proměnná – 1 = Asie; 2 = Evropa; 3 = Amerika

2.7.5 Beerman model

Tento model byl vytvořen v roce 1976 a je tedy nejstarším ze všech vybraných modelů. Byl sestaven pro řemeslné a výrobní podniky. Jako vzorek bylo použito 21 společností, které ukončily svoji činnost. Data pochází z období let 1966-1971 (Altman, 2002).

Rovnice výpočtu:

$$\begin{aligned} BDF = & 0,217 X_1 + (-0,063) X_2 + 0,012 X_3 + 0,077 X_4 + (-0,105) X_5 \\ & + (-0,813) X_6 + 0,165 X_7 + 0,161 X_8 + 0,268 X_9 + 0,124 X_{10} \end{aligned}$$

Kde:

$X_1 =$ odpisy DHM

$X_2 =$ přírůstek DHM / odpisy DHM

$X_3 =$ zisk před zdaněním / tržby

$X_4 =$ závazky vůči bankám / tržby

$X_5 =$ zásoby / tržby

$X_6 =$ cash flow / celkové dluhy

$X_7 =$ celkové dluhy / aktiva

$X_8 =$ zisk před zdaněním / aktiva celkem

$X_9 =$ tržby / aktiva celkem

$X_{10} =$ zisk před zdaněním / celkové dluhy

V případě, že výsledné BDF nabývá menší hodnoty než 0,3, společnost vykazuje pozitivní finanční vývoj. V opačném případě lze očekávat bankrot.

Nejvyšší dosažená přesnost modelu nabývala hodnoty 90,5 % (Altman, 2002).

2.8 Způsob hodnocení bankrotních modelů

Následující kapitola se zabývá hodnocením bankrotních modelů. K hodnocení kvality a úspěšnosti bankrotních modelů se nejčastěji využívá testování jejich přesnosti a metoda ROC křivky. Každý model se potýká s jistým omezením. Problematika omezení modelů je taktéž součástí této části práce.

2.8.1 ROC křivky

V historii byly ROC křivky využívány během druhé světové války pro analýzu radarových snímků. Později našly uplatnění v mnoha dalších oborech. V dnešní době jsou využívány především jako nástroj pro vyhodnocení schopnosti bankrotních modelů. ROC křivky porovnávají minimálně dvě rozdílná klasifikační pravidla. Tato metoda je považována za komplexní porovnání zkoumaných modelů (The magnificent ROC, 2007).

Při sestavování ROC křivky je nutné rozřadit vzorek vybraných společností na bankrotující a zdravé podniky na základě jejich specifických vlastností. Dále je nutné vyhodnotit, zda model zařadil společnosti do správné skupiny, tedy určit jeho přesnost. Při vyhodnocování přesnosti daného modelu vznikají chyby prvního a druhého typu. Chyba prvního typu představuje situaci, kdy daná společnost zbankrotovala, ale model ji označil za zdravou společnost. Chyba druhého typu značí opačnou situaci, tedy zařazení zdravého podniku do skupiny bankrotních (Fawcett, 2006).

Tab. 1: Zařazení daného vzorku
(Vlastní zpracování dle: The Magnificent ROC, 2007)

Predikce	Skutečný stav	
	Aktivní	Bankrotní
Aktivní	Správná klasifikace (TN)	Chyba prvního typu (FN)
Bankrotní	Chyba druhého typu (FP)	Správná klasifikace (TP)


Tabulka výše definuje čtyři následující výstupy:

- **True negative (TN)** = aktivní společnost byla správně zařazena do skupiny aktivních společností,
- **True positive (TP)** = bankrotní společnost byla správně zařazena do skupiny bankrotních společností,
- **False negative (FN)** = bankrotní společnost byla chybně zařazena do skupiny aktivních společností,
- **False positive (FP)** = aktivní společnost byla chybně zařazena do skupiny bankrotních společností (Fawcett, 2006).

Z těchto výstupů lze dále vypočítat následující charakteristiky:

- **True positive rate (TPR)** = sensitivita; míra skutečné pozitivity:
 $TPR = TP/(TP+FN)$,
- **False positive rate (FPR)** = falešný poplach; míra falešné pozitivity:
 $FPR = FP/(FP+TN)$,
- **Specificity (SPC)** = specifická:
 $SPC = TN/(TN+FP)$,
- **Accuracy (ACC)** = míra správné klasifikace:
 $ACC = (TP+TN)/(TP+TN+FP+FN)$ (Fawcett, 2006).

Grafy ROC křivek jsou dvourozměrné grafy. Na ose X je znázorněna FPR (false positive rate) a na ose Y je TPR (true positive rate). Grafy vyjadřují porovnání mezi TPR a FPR (Fawcett, 2006).



Graf 1: ROC graf
(Zdroj: Fawcett, 2006)

Je nutné zmínit několik bodů v tomto grafu. Bod (0;0) nikdy neprezentuje pozitivní klasifikaci - aktivní společnost je klasifikována jako bankrotní. Opakem je bod (1;1), který klasifikuje bankrotní společnost jako aktivní. Dokonalou klasifikaci znázorňuje bod (0;1). Bod, který leží severozápadně od jiného, je považován za lepší. Body blíží se k ose X jsou označovány jako „konzervativní“. Vytváří pozitivní klasifikaci pouze v případě, že existují silné důkazy. Body ležící v pravé polovině grafu jsou označovány za „liberální“. Tyto body vytváří pozitivní klasifikaci i se slabými důkazy. Body, které se nachází v blízkosti diagonály, jsou považovány za náhodné hádání, jsou však lepší než body nacházející se pod diagonálou (Fawcett, 2006).

K účelu porovnání ROC křivek jednotlivých modelů slouží ukazatel AUC (Area Under the Curve), tedy plocha pod křivkou. Hodnota tohoto ukazatele se vždy pohybuje mezi hodnotou 0 a 1, přesto by žádný model, který má být využíván k predikci, neměl dosahovat hodnoty nižší než 0,5. Obecně platí, že čím více se hodnota AUC blíží k 1, tím je model kvalitnější (Fawcett, 2006).

ROC křivky (Receiver Operating Characteristic) slouží jako technika pro vizualizaci, organizaci a výběr klasifikátorů založených na jejich výkonu. Představují užitečnou metodu grafů výkonu. Jsou považovány za koncepčně jednoduché, avšak existují

i některé neviditelné složitosti, které se objevují při jejich použití ve výzkumu (Fawcett, 2005).

2.8.2 Omezení modelů

Při používání klasických statistických metod jako jsou MDA a LR se vyskytují určité problémy, které následně omezují dané modely. Tyto problémy se týkají především předpokladu bipolárně závislých proměnných, metodiky výběru souboru dat vzorových firem, předpokladu stacionarity a nestability dat, výběru nezávislých proměnných, využití ročních finančních výkazů z účetní závěrky a časové dimenze (Vochozka, 2011).

Při tvorbě modelů s využitím MDA a LR se předpokládá, že závislá proměnná je dichotomická, a tím pádem jsou soubory bankrotujících a zdravých podniků správně definovány a znatelně odděleny. V praxi však neexistuje jednoznačné kritérium, které by společnosti do těchto dvou skupin rozdělilo. Tento problém lze částečně vyřešit využitím další skupiny tzv. „šedé zóny“, kam se řadí podniky, u kterých není jasná jejich situace. Rozdělení podniků do jednotlivých skupin zcela závisí na formě definice selhávající společnosti, které se u každého autora liší (Vochozka, 2011).

Většina autorů využívá pro sestavení modelu vyvážený soubor dat, který obsahuje stejné množství bankrotujících a aktivních společností. Tyto společnosti jsou párovány podle vybraných vlastností. Tato metoda má však také jistá úskalí. Pokud je soubor neselhávajících podniků založen na vlastnostech vzorku bankrotujících podniků, zvyšuje se pravděpodobnost, že vybraný vzorek nebude reprezentativní pro všechny zdravé podniky. Dále může docházet k výběru chybného vzorového souboru např. díky podhodnocení nebo naopak přecenění některých vlastností (Vochozka, 2011).

Většina modelů za účelem predikce bankrotu využívá poměrové ukazatele, pro které čerpá informace z ročních finančních výkazů. V tomto případě se spoléhá na to, že roční účetní závěrky obsahují relevantní informace a poskytují tak pravdivý pohled na finanční situaci dané společnosti. Spousta podniků ovšem s těmito daty manipuluje a ne vždy zveřejňuje pravdivé informace (Vochozka, 2011).

Přesnost jednotlivých modelů ovlivňuje stabilita vztahů mezi proměnnými v čase. V případě jejich nestability klasické statistické modely často vykazují nesrovnalosti,

což značí nepříznivé prognózy daného modelu v budoucnu. Velký vliv na nepřesnost údajů mají např. změny inflace nebo úrokových sazeb a fáze hospodářského cyklu, ve které se daná ekonomika aktuálně nachází. Z toho vyplývá, že v případě použití historických modelů, je nutné počítat s tím, že nebude dosažena jejich původní přesnost (Grice, Dugan, 2001).

Dalším faktorem, který ovlivňuje přesnost bankrotních modelů, je metodika výběru souboru dat vzorových firem. V případě, že se jedná o nenáhodná výběr vzorků, lze očekávat zkreslení jejich pravděpodobnosti selhání a ovlivnění výsledků celkové klasifikace. Přesnost výsledku modelu, který je založen na nenáhodných vzorcích, tak nelze zevšeobecnit a může být zavádějící (Vochozka, 2011).

3 ZHODNOCENÍ SOUČASNÉ EFEKTIVNOSTI VYBRANÝCH BANKROTNÍCH MODELŮ

Tato část diplomové práce se zaměřuje na zhodnocení současné efektivnosti pěti vybraných bankrotních modelů, kterými jsou Generický model, Slefendorfas model, Brezigar-Masten, Masten model, Globální bankrotní model a Beerman model. Zaměřuje se na výpočet jejich spolehlivosti při aplikování na vybraný vzorek společností a jejich ROC křivky.

K testování jsou využita data pocházející z databáze Amadeus, která obsahují celkem 88 společností, které jsou rovnoměrně rozděleny na 44 bankrotujících a 44 aktivních. Jedná se o společnosti z odvětví zpracovatelského průmyslu v České republice, které se dle jejich velikostí řadí mezi malé nebo střední podniky.

3.1 Přesnost Generického modelu

Generický model byl sestaven pomocí logit metody. Vzorek pro jeho testování tvořilo přibližně 90 bankrotních společností v USA, které byly následně srovnávány se stejným počtem finančně zdravých společností podobné velikosti z období 2008-2015. Data byla čerpána z databáze COMPUSTAT. Spolehlivost modelu podle autorů odpovídá 86,4 % v případě aktivních a 93,6 % u bankrotních společností (Bhandari, Johnson-Syder, 2018).


Model byl následně testován na vybraném vzorku českých společností z odvětví zpracovatelského průmyslu. Výsledky testování znázorňují následující tabulky.

Tab. 2: Generický model – přesnosti aktivních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

AKTIVNÍ SPOLEČNOSTI					
	T-1	T-2	T-3	T-4	T-5
počet správně zařazených (<0,5)	4	7	9	7	10
počet nesprávně zařazených (>0,5)	5	3	3	5	0
celkový počet	9	10	12	12	10
přesnost	44,44 %	70,00 %	75,00 %	58,33 %	100,00 %

V tabulce č. 2 lze vidět rozložení správného a nesprávného vyhodnocení aktivních společností v období posledních 5 let. Jako cut-off score byla použita hranice 0,5, což je běžně používaná hodnota pro logit modely. Přesnost pro aktivní společnosti vykazuje nejnižší hodnotu v období T-1, kdy byly správně vyhodnoceny pouze 4 z 9 aktivních společností, čímž přesnost modelu dosáhla hodnoty 44,44 %. Naopak nejvyšší hodnoty dosahuje v roce T-5, kdy přesnost dosáhla hodnoty 100 %, tudíž bylo správně vyhodnoceno 10 z 10 aktivních společností. V roce T-2 model vykazuje přesnost 70 %, v roce T-3 75 % a v roce T-4 58,33 %.

Graf níže zachycuje absolutní četnost správného a nesprávného zařazení aktivních společností.



Graf 2: Generický model - absolutní četnost přesnosti aktivních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)


Výsledky testování přesnosti pro bankrotní společnosti jsou v následující tabulce.

Tab. 3: Generický model – přesnosti bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

BANKROTNÍ SPOLEČNOSTI					
	T-1	T-2	T-3	T-4	T-5
počet správně zařazených (>math>>0,5</math>)	28	26	26	24	22
počet nesprávně zařazených (<math><0,5</math>)	6	6	4	7	10
celkový počet	34	32	30	31	32
přesnost	82,35 %	81,25 %	86,67 %	77,42 %	68,75 %

V tabulce výše je zachycena přesnost modelu v případě správného vyhodnocení bankrotních společností v období 5 let před bankrotem. Nejvyšší přesnost vykazuje model v roce T-3, kdy hodnota přesáhla 86 %, tudíž bylo správně zařazeno 26 z celkových 30 společností. V posledních dvou letech před bankrotem T-1 a T-2 přesnost modelu přesáhla hranici 80 %. V roce T-4 bylo vyhodnoceno 24 z celkových 31 bankrotních společností a přesnost tedy dosáhla 77,42 %. Nejnižší hodnoty 68,75 % nabývala přesnost modelu v roce T-5, kdy bylo správně zařazeno 22 z 32 bankrotních společností.

Vyjádření absolutní četnosti pro bankrotní společnosti zachycuje graf níže.



Graf 3: Generický model - absolutní četnost přesnosti bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Celková přesnost tohoto modelu je vyjádřena v následující tabulce.

Tab. 4: Generický model - celková přesnost
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

CELKOVÁ PŘESNOST					
	T-1	T-2	T-3	T-4	T-5
přesnost	74,42 %	78,57 %	83,33 %	72,09 %	76,19 %

Předchozí tabulka znázorňuje celkovou přesnost Generického modelu v jednotlivých letech při testování na vybraném vzorku dat českých společností. Díky poměrně vysokým hodnotám přesnosti v obou případech jak správného zařazení aktivních, tak bankrotních společností, dosahuje celková přesnost poměrně vysokých hodnot. Nejvyšší hodnoty

dosahuje v roce T-3, kdy byla vyčíslena na 83,33 %. Nejnižší, přesto stále poměrně vysokou hodnotu 72,09 %, nabývá v roce T-4. Ve zbylých letech pak dosahuje v rozmezí 74 % - 79 %.

Tab. 5: Generický model - srovnání přesností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

SROVNÁNÍ PŘESNOSTÍ		
	původní	testovaná
bankrotní	86,40 %	79,25 %
aktivní	93,60 %	69,81 %

V tabulce výše je vyjádřeno srovnání původních a testovaných přesností při správném zařazení bankrotních a aktivních podniků. U obou případů došlo k poklesu oproti původní přesnosti. V případě bankrotních podniků došlo k poklesu testované přesnosti z původních 86,40 % na 79,25 %. V druhém případě došlo k výraznějšímu poklesu, a to z původních 93,60 % na 69,81 %. Je tedy možné říci, že vyšší spolehlivosti při testování na vybraném vzorku českých společností z odvětví zpracovatelského průmyslu dosahuje Generický model v případě správného zařazení bankrotních společností. Je však nutné uvažovat, že spolehlivost daného modelu ovlivňuje fakt, že byl model původně sestaven a testován na vzorku dat amerických společností.

3.2 Přesnost Slefendorfasova modelu

Pro sestavení Slefendorfasova modelu byla použita vícerozměrná diskriminační analýza s finančními ukazateli. Jako vzorek posloužila data ze 145 společností působících v Litvě (72 bankrotujících a 73 aktivních). Data pochází z období let 2007-2012. Hraničním bodem pro určení, zda společnost spadá do skupiny aktivních nebo bankrotujících společností je 0. Je-li hodnota koeficientu nižší než 0, je společnost označena za bankrotní. Pokud je hodnota koeficientu naopak vyšší než 0, společnost je považována za aktivní (Slefendorfas, 2016).

V případě tohoto modelu nebyla provedena analýza za jednotlivé sledované roky, neboť rovnice výpočtu daného modelu obsahuje ukazatele, které jsou složeny z proměnných napříč všemi roky. V následující tabulce je tedy uvedena jedna hodnota vyjadřující přesnost v případě aktivních společností a druhá hodnota připadající bankrotním společnostem.


Tab. 6: Slefendorfas model - přesnost aktivních a bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

	BANKROTNÍ	AKTIVNÍ
počet správně zařazených	6	23
počet nesprávně zařazených	5	14
celkový počet	11	37
přesnost	54,55 %	62,16 %

Jak bylo vysvětleno výše, v tabulce lze vidět hodnoty vyjadřující přesnost jak pro aktivní, tak bankrotní společnosti. V případě bankrotních společností dokázal model správně zařadit 6 z celkových 11 společností a jeho hodnota tedy dosahuje 54,55 %. V druhém případě model zařadil 23 z celkových 37 aktivních společností, tudíž jeho přesnost dosahuje 62,16 % v oblasti správné kategorizace aktivních společností. V obou případech dosahují vyšší hodnoty než 50 %, lze tedy říci, že výsledky přesnosti modelu mají vyšší vypovídající hodnoty než v případě použití pouze náhodného výběru. Rozdíl hodnot přesností bankrotních a aktivních společností dosahuje více než 7,50 %. Tato skutečnost je ovlivněna také rozdílnou velikostí vzorku skupin společností, kdy aktivních společností bylo více než trojnásobné množství.

Celková přesnost v případě Slefendorfas modelu dosahuje hodnoty 60,42 %.

Číselné vyjádření klasifikace bankrotních a aktivních společností zachycuje následující graf.



Graf 4: Slefendorfas model – absolutní četnost přesnosti aktivních a bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Dále je vyobrazeno srovnání původních a testovaných přesností.

Tab. 7: Slefendorfas model - srovnání přesností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

SROVNÁNÍ PŘESNOSTÍ		
	původní	testovaná
bankrotní	87,70 %	54,55 %
aktivní	90,30 %	62,16 %

Tabulka výše vyjadřuje srovnání původních přesností dle studie a přesností, které vyplynuly z testování na datech českých společností. Původní přesnost pro skupinu bankrotních společností je uváděna ve výši 87,70 %. Tato hodnota je oproti testované, která vykazuje hodnotu 54,55 %, výrazně vyšší. V druhém případě došlo k podobně výraznému poklesu testované přesnosti oproti původní, kdy původní přesnost dosahovala hodnoty 90,30 % a klesla na 62,16 %. Tyto výsledky mohou být ovlivněny rozdílnou velikostí vzorků. Dále je nutné říci, že model byl původně vytvořen a testován na slovinských společnostech, což má také vliv na tyto výsledky.

3.3 Přesnost Brezigar-Masten, Masten modelu

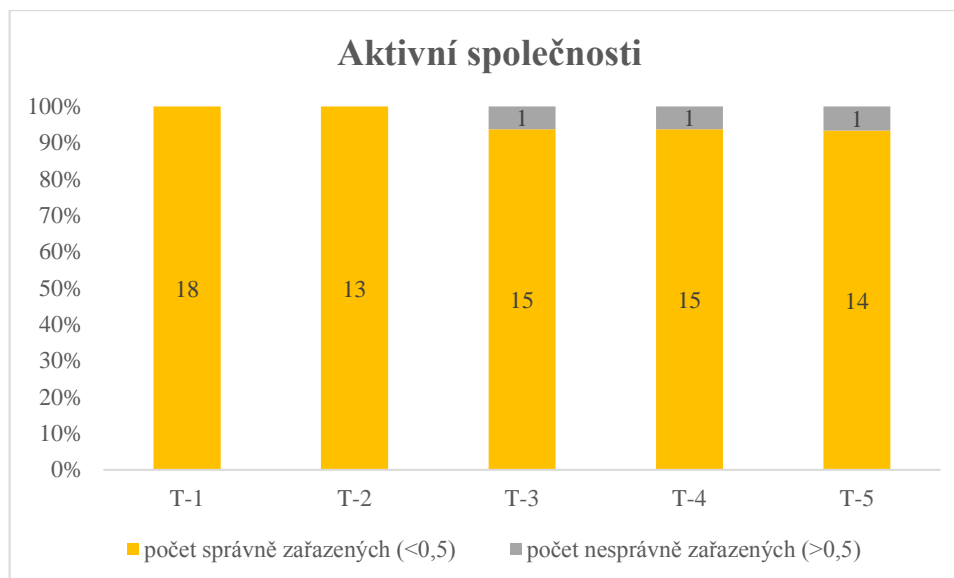
Brezigar-Masten, Masten model byl sestaven pomocí nového postupu výběru prediktorů, který je založený na metodě klasifikačních a regresních stromů. Bylo sestaveno několik verzí. Nejlepší výsledek byl získán za použití logit modelu s kategoričnými proměnnými na základě výsledku aplikace modelu CART. Jako vzorek bylo využito 888 slovinských společností z období 1995-2001. Spolehlivost modelu dle autorů dosahuje hodnoty 91,70 % v případě správného zařazení bankrotních společností a 82,40 % u aktivních společností.

Tab. 8: Brezigar-Masten, Masten model - přesnosti aktivních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

AKTIVNÍ SPOLEČNOSTI					
	T-1	T-2	T-3	T-4	T-5
počet správně zařazených (<0,5)	18	13	15	15	14
počet nesprávně zařazených (>0,5)	0	0	1	1	1
celkový počet	18	13	16	16	15
přesnost	100,00 %	100,00 %	93,75 %	93,75 %	93,33 %

Tabulka výše znázorňuje vypočtenou přesnost pro správné zařazení aktivních společností při testování Brezigar-Masten, Masten modelu na vybraném vzorku dat. V posledních dvou sledovaných letech dosáhla přesnost modelu 100 %, tudíž v roce T-1 bylo správně zařazeno 18 z 18 aktivních společností a v roce T-2 dokázal model správně určit 13 ze 13 aktivních společností. Ve zbylých třech letech byla ve všech případech překročena hranice 93 %. Lze tedy konstatovat, že se tento model jeví jako vhodný pro klasifikaci aktivních společností.

Vyjádření přesnosti v absolutních číslech lze vidět v následujícím grafu.



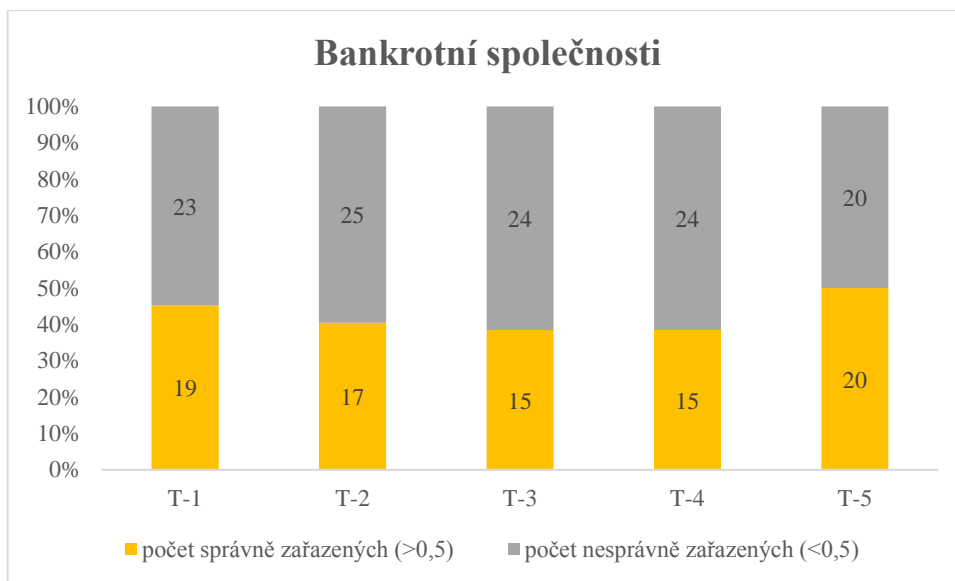
Graf 5: Brezigar-Masten, Masten model – absolutní četnost přesnosti aktivních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Přesnost správného zařazení bankrotních společností zobrazuje tabulka č. 9.

Tab. 9: Brezigar-Masten, Masten model - přesnosti bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

BANKROTNÍ SPOLEČNOSTI					
	T-1	T-2	T-3	T-4	T-5
počet správně zařazených (>0,5)	19	17	15	15	20
počet nesprávně zařazených (<0,5)	23	25	24	24	20
celkový počet	42	42	39	39	40
přesnost	45,24 %	40,48 %	38,46 %	38,46 %	50,00 %

V případě bankrotních společností, které zachycuje předchozí tabulka, už výsledky tolik pozitivní nebyly. Nejvyšší hodnoty dosáhla přesnost správného zařazení bankrotních společností v roce T-5, kdy vykazuje hodnotu 50 %. Správně bylo zařazeno 20 ze 40 bankrotních společností. Následujících dvou letech T-4 a T-3 dosáhla přesnost stejné hodnoty 38,46 %, kdy bylo správně zařazeno 15 z 39 bankrotních společností. V roce T-2 došlo k mírnému nárůstu na 40,48 %. V posledním roce před bankrotem překročila přesnost modelu 45 %. Na základě toho, že ani v jednom ze sledovaných let nepřekročila spolehlivost hranici 50 %, lze konstatovat, že stejných výsledků by mohlo být dosaženo pomocí náhodného výběru.



Graf 6: Brezigar-Masten, Masten model – absolutní četnost přesnosti bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Dále je vyjádřena celková přesnost modelu v jednotlivých letech.

Tab. 10: Brezigar-Masten, Masten model – celková přesnost
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

CELKOVÁ PŘESNOST					
	T-1	T-2	T-3	T-4	T-5
přesnost	61,67 %	54,55 %	54,55 %	54,55 %	61,82 %

Tabulka č. 10 zachycuje celkovou přesnost Brezigar-Masten, Masten modelu na testovaných datech. Tento model dosahuje ve všech sledovaných letech nižších hodnot než předchozí model. Nejvyšší hodnoty přesnosti nabývá v roce T-5, kdy dosáhla 61,82 %. Nepatrně nižší hodnoty 61,67 % dosáhla přesnost v posledním sledovaném roce T-1. Ve zbylých letech dosáhl model stejné hodnoty 54,55 % celkové přesnosti.

Tab. 11: Brezigar-Masten, Masten model – srovnání přesností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

SROVNÁNÍ PŘESNOSTÍ		
	původní	testovaná
bankrotní	91,70 %	42,57 %
aktivní	82,40 %	96,15 %

Výše uvedená tabulka vyjadřuje srovnání původních a testovaných přesností pro oba typy společností. V případě správného zařazení bankrotních společností došlo k výraznému poklesu z původních 91,70 % na 42,57 %. Tato skutečnost značí, že tento model není

příliš vhodný k predikci bankrotu podniku. U klasifikace aktivních společností došlo naopak k nárůstu přesnosti z původních 82,40 % na 96,15 %. V tomto případě lze model považovat za spolehlivý v případě správného zařazování aktivních společností.

3.4 Přesnost Globálního bankrotního modelu


Globální bankrotní model byl vytvořen za účelem predikce bankrotu v jakémkoliv odvětví v jakémkoliv zemi. Model byl sestaven pomocí logistické regrese založené na finančních proměnných. Jako vzorek byly využity data z velkého množství společností z Asie, Ameriky a Evropy v období 1990-2013. Původní přesnost modelu dosahovala hodnoty 90,10 % v obou případech správné klasifikace společností.

Tab. 12: Globální model - přesnosti aktivních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

AKTIVNÍ SPOLEČNOSTI					
	T-1	T-2	T-3	T-4	T-5
počet správně zařazených (<0,5)	8	5	8	5	4
počet nesprávně zařazených (>0,5)	35	38	34	34	36
celkový počet	43	43	42	39	40
přesnost	18,60 %	11,63 %	19,05 %	12,82 %	10,00 %

Ve výše uvedené tabulce lze vidět přesnost správného zařazení aktivních společností v období T-5 až T-1. Ve všech sledovaných letech dosahuje model velice nízkých hodnot. Ani v jednom ze sledovaných let nepřekročil hranici 20 %. Této hodnotě se jeho přesnost přiblížila nejvíce v roce T-3, kde nabývala 19,05 %. Nejnižší hodnoty dosáhla jeho přesnost v prvním sledovaném roce T-5, a to pouhých 10 %. Lze tedy konstatovat, že se tento model se jeví jako značně nevhodný pro určování aktivních společností. Mnohem lepšího výsledku by bylo možné dosáhnout pomocí náhodného výběru.

Přesnost správného zařazení aktivních společností vyjádřená v absolutních hodnotách je také zachycena v následujícím grafu.




Graf 7: Globální model – absolutní četnost přesností aktivních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Dále je vyjádřena přesnost pro bankrotní společnosti.

Tab. 13: Globální model - přesnosti bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

BANKROTNÍ SPOLEČNOSTI					
	T-1	T-2	T-3	T-4	T-5
počet správně zařazených (>0,5)	22	21	20	18	15
počet nesprávně zařazených (<0,5)	5	3	2	2	4
celkový počet	27	24	22	20	19
přesnost	81,48 %	87,50 %	90,91 %	90,00 %	78,95 %

Tabulka č. 13 vyjadřuje správné zařazení bankrotních společností. Oproti předchozím výsledkům správného zařazování aktivních společností, dosáhl model v tomto případě velice příznivých výsledků. Nejvyšší hodnoty dosáhla jeho přesnost ve třetím sledovaném roce, kde nabyla hodnoty 90,91 %, kdy bylo správně zařazeno 20 z 22 bankrotních společností. Podobně vysokého výsledku dosáhla přesnost v předchozím sledovaném roce, kdy dosáhla hodnoty 90 %. Nejnižší přesto stále vysoká hodnota byla dosažena v prvním sledovaném roce T-5 a nabývala hodnoty 78,95 %. V tomto případě byla správně zařazeno 15 z 19 bankrotních společností. Tento model lze tedy považovat za spolehlivý v oblasti správného zařazování bankrotních společností.



Graf 8: Globální model – absolutní četnost přesností bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Celková přesnost Globálního modelu je zobrazena v tabulce níže.

Tab. 14: Globální model - celková přesnost

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

CELKOVÁ PŘESNOST					
	T-1	T-2	T-3	T-4	T-5
přesnost	42,86 %	38,81 %	43,75 %	38,98 %	32,20 %

Díky výrazně nízkým hodnotám přesnosti u aktivních společností, nedosahuje model příliš pozitivních výsledků u celkové přesnosti. Nejnížší hodnoty nabývá celková přesnost v prvním sledovaném roce T-5, kde dosáhla hodnoty pouze 32,20 %. Nejvyšší hodnota byla naopak zaznamenána v posledním sledovaném roce T-1, kde dosáhla 42,86 %. Ani v jednom ze sledovaných let však nepřesáhla hodnota hranici 50 %, lze proto konstatovat, že model nemá dostatečně vypovídající hodnotu a lepšího výsledku by opět bylo možné dosáhnout náhodným výběrem.

Tab. 15: Globální model - srovnání přesností

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

SROVNÁNÍ PŘESNOSTÍ		
	původní	testovaná
bankrotní	90,10 %	85,71 %
aktivní	90,10 %	14,49 %

Výše zaznamenané srovnání původních a testovaných přesností modelu naznačuje, že v případě správné kategorizace aktivních společností, se nedá na Globální model spoléhat. Výsledek, který vyplynul z testování na datech českých společností, nepřekročil hranici 15 %. Původně deklarovaná přesnost byla uvedena na úrovni 90,10 % v obou případech správné kategorizace společností. V případě testované přesnosti u bankrotních společností dosáhl model podobně pozitivního výsledku 85,71 %. Model je tedy možné považovat za spolehlivý v případě správného zařazování bankrotních společností.

3.5 Přesnost Beermanova modelu


Beerman model je nejstarším ze všech vybraných modelů. Byl sestaven pro řemeslné a výrobní podniky. Jako vzorek bylo použito 21 zbankrotovaných společností z období let 1966-1971. Nejvyšší dosažená přesnost modelu nabývala hodnoty 90,5 % pro správné zařazení bankrotních společností.

Tab. 16: Beerman model – přesnosti aktivních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

AKTIVNÍ SPOLEČNOSTI					
	T-1	T-2	T-3	T-4	T-5
počet správně zařazených (<0,3)	38	39	26	26	23
počet nesprávně zařazených (>0,3)	1	1	0	0	0
celkový počet	39	40	26	26	23
přesnost	97,44 %	97,50 %	100,00 %	100,00 %	100,00 %

Tabulka výše zachycuje přesnost dosaženou u správného zařazení aktivních společností. Ve všech letech dosáhla velice pozitivních výsledků. V letech T-5 až T-3 nabývala přesnost hodnoty 100 %, tudíž zařadila všechny aktivní společnosti do správné skupiny. V posledních dvou sledovaných letech došlo k nesprávnému zařazení jedné společnosti z celkového počtu 39 a 40 aktivních společností, čímž došlo k mírnému poklesu přesnosti.

Absolutní četnost přesností lze vidět v následujícím grafu.



Graf 9: Beerman model – absolutní četnost přesností aktivních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)


Dále byla testovaná přesnost pro bankrotní společnosti.

Tab. 17: Beerman model – přesnosti bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

BANKROTNÍ SPOLEČNOSTI					
	T-1	T-2	T-3	T-4	T-5
počet správně zařazených (>0,3)	13	13	11	11	10
počet nesprávně zařazených (<0,3)	1	0	0	0	0
celkový počet	14	13	11	11	10
přesnost	92,86 %	100,00 %	100,00 %	100,00 %	100,00%

V případě správné klasifikace bankrotních společností docházelo k podobně pozitivním výsledkům jako u skupiny aktivních. K 100 % klasifikaci došlo ve čtyřech z pěti sledovaných let. V posledním sledovaném roce před bankrotem se modelu podařilo správně klasifikovat 13 z celkových 14 bankrotních společností a přesnost poklesla na 92,86 %. Nicméně je nutné zmínit, že celkový počet bankrotních společností byl několikanásobně nižší než v případě aktivních společností.

Absolutní četnost správného zařazení bankrotních společností zachycuje následující graf.



Graf 10: Beerman model – absolutní četnost přesností bankrotních společností
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Celková přesnost Beerman modelu v jednotlivých je vyjádřena v následující tabulce.

Tab. 18: Beerman model - celková přesnost

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

CELKOVÁ PŘESNOST					
	T-1	T-2	T-3	T-4	T-5
přesnost	96,23 %	98,11 %	100,00 %	100,00 %	100,00 %

Jak již bylo komentováno výše, přesnost správné klasifikace nabývala v obou případech značně pozitivních hodnot. Lze tedy říci, že Beerman model je výrazně spolehlivý.

Tab. 19: Beerman model - srovnání přesností

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

SROVNÁNÍ PŘESNOSTÍ		
	původní	testovaná
bankrotní	90,50 %	98,31 %
aktivní	-	98,70 %


V případě správného zařazení bankrotních společností byla původní přesnost udána na hladině 90,50 %. Po testování na datech českých společností z oblasti zpracovatelského průmyslu dosáhla ještě pozitivnějšího výsledku. U aktivních společností není uvedena původní přesnost, nelze tedy provést srovnání s testovanou přesností, která však dosáhla podobně vysoké hodnoty jako u bankrotu.

3.6 ROC křivky vybraných bankrotních modelů

V této části práce budou okomentovány vytvořené ROC křivky jednotlivých bankrotních modelů, které byly vytvořeny pomocí programu IBM SPSS.

V případě ROC křivek jsou sledovány dvě hodnoty, které jsou vždy zaznamenány v tabulce pod grafem ROC křivky, a to hodnota plochy pod křivkou (AUC) a test statistické významnosti, jehož hodnota vyjadřuje, zda je výsledná hodnota plochy pod křivkou významná. V případě, že je hodnota AUC nižší než 0,5, přesnost modelu je považována za nízkou. Hraničním bodem pro významnost AUC je 0,05. Pokud významnost nepřekročí hranici 5 %, AUC je považována za nedůvěryhodnou.

První graf znázorňuje ROC křivku pro **Generický model**.



Graf 11: Generický model - ROC křivka
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Níže je zobrazeno číselné vyjádření plochy pod křivkou a její významnost.

Tab. 20: Generický model – plocha pod křivkou
 (Zdroj: Vlastní zpracování pomocí IBM SPSS)


Area Under the Curve

Test Result Variable(s)				
Area	Std. Error ^a	Asymptotic Sig. ^b	Asymptotic 95% Confidence Interval	
			Lower Bound	Upper Bound
.706	.084	.039	.541	.870

a. Under the nonparametric assumption
 b. Null hypothesis: true area = 0.5

Jak lze pozorovat v tabulce výše, hodnota plochy pod křivkou Generického modelu dosahuje hodnoty 0,706. Tuto hodnotu lze dle výsledků považovat za významnou na 5% hladině, což znamená, že v případě změny dat by se vyčíslená hodnota významně neodlišovala.

Další graf znázorňuje ROC křivku pro **Slefendorfas model**.



Graf 12: Slefendorfas model - ROC křivka
 (Zdroj: Vlastní zpracování pomocí IBM SPSS)

Následující tabulka zachycuje hodnotu plochy pod křivkou a její významnost.

Tab. 21: Slefendorfas model - plocha pod křivkou
(Zdroj: Vlastní zpracování pomocí IBM SPSS)


Area Under the Curve

Test Result Variable(s)				
Area	Std. Error ^a	Asymptotic Sig. ^b	Asymptotic 95% Confidence Interval	
			Lower Bound	Upper Bound
.495	.101	.962	.298	.692

a. Under the nonparametric assumption
b. Null hypothesis: true area = 0.5

V případě Slefendorfas modelu nabývá hodnota pod křivkou čísla 0,495. Test statistické významnosti dosáhl vyšší hodnoty než předchozí model a to 0,962. Na základě této skutečnosti lze konstatovat, že hodnota pod křivkou není statisticky významná.

Následující graf zachycuje ROC křivku pro **Brezigar-Masten, Masten model**.



Graf 13: Brezigar Masten, Masten model - ROC křivka
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Následující tabulka je číselným vyjádření plochy pod křivkou a její významnosti.

Tab. 22: Brezigar-Masten, Masten model - plocha pod křivkou
 (Zdroj: Vlastní zpracování pomocí IBM SPSS)


Area Under the Curve				
Test Result Variable(s)				
Area	Std. Error ^a	Asymptotic Sig. ^b	Asymptotic 95% Confidence Interval	
			Lower Bound	Upper Bound
.914	.038	.000	.839	.989

a. Under the nonparametric assumption

b. Null hypothesis: true area = 0.5

V případě Brezigar-Masten, Masten modelu nabývá AUC vysoké hodnoty 0,914. Tato hodnota je statisticky významná na 1% hladině.

Na dalším grafu je vyobrazena ROC křivka **Globálního modelu**.



Graf 14: Global model - ROC křivka
 (Zdroj: Vlastní zpracování pomocí IBM SPSS)

Následující tabulka vyjadřuje hodnotu plochy pod křivkou a její významnost.

Tab. 23: Global model - plocha pod křivkou
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Area Under the Curve


Test Result Variable(s)

Area	Std. Error ^a	Asymptotic Sig. ^b	Asymptotic 95% Confidence Interval	
			Lower Bound	Upper Bound
.422	.081	.341	.265	.580

a. Under the nonparametric assumption
b. Null hypothesis: true area = 0.5

U Globálního modelu je hodnota plochy pod křivkou 0,422. Její statistická významnost dosahuje hodnoty 0,341, což značí, že není významná.

Graf níže představuje ROC křivku pro **Beerman model**.



Graf 15: Beerman model - ROC křivka
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Tabulka níže představuje hodnoty vztahující se k ROC křivce, a to hodnotu plochy pod křivkou a její významnost.

Tab. 24: Beerman model – plocha pod křivkou
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Area Under the Curve

Test Result Variable(s)				
Area	Std. Error ^a	Asymptotic Sig. ^b	Asymptotic 95% Confidence Interval	
			Lower Bound	Upper Bound
.869	.053	.000	.765	.974

a. Under the nonparametric assumption
b. Null hypothesis: true area = 0.5

V případě Beerman modelu nabývá hodnota plochy pod křivkou poměrně vysokého čísla 0,869. Její hodnota je statisticky významná na úrovni 1 %.

3.7 T-test proměnných vybraných bankrotních modelů

Dále bylo u jednotlivých modelů provedeno testování významnosti proměnných, které napomáhá k poskytnutí lepšího přehledu o účinnosti modelů, a je možné jej vidět v tabulkách níže. Tyto tabulky zachycují několik hodnot t-testu. T-hodnota a p-val. (1) představují hodnoty testovaného kritéria za předpokladu stejných rozptylů. T-hodnota (2) a p-val. (2) naopak předpokládají samostatné odhady rozptylů.

Následující tabulka znázorňuje t-test provedený u **Generického modelu**.

Tab. 25: Generický model - t-test
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Proměnná	průměr	průměr	t-hodnota	stupně volnosti	p-val. (1)	t-hodnota (2)	stupně volnosti	p-val. (2)	F-test
	(bankrot.)	(aktiv.)							(p-val.)
(CFO+INT+TAX)/ INT	21.596	1207.631	-0.646	45	0.521624	-1.252	36.011	0.218511	0.000000
CFO/CL	-0.080	0.486	-2.788	56	0.007240	-2.111	18.019	0.048973	0.000548
CFO/SALES	-3.005	0.077	-1.682	57	0.098010	-1.011	15.001	0.328076	0.000000
CFO/TA	30.731	0.100	1.635	57	0.107514	0.983	15.000	0.341388	0.000000
EBIT/CFO	-1.121	0.476	-2.846	57	0.006143	-1.855	15.841	0.082336	0.000000

Výsledek t-testu provedeného u Generického modelu naznačuje, že za významný ukazatel lze považovat pouze druhý (CFO/CL), který jako jediný ze všech ukazatelů modelu dosáhl významnosti na úrovni 5 %.

Tabulka níže zachycuje t-test provedený u **Slefendorfas modelu**.

Tab. 26: Slefendorfas model - t-test

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Proměnná	průměr	průměr	t-hodnota	stupně volnosti	p-val. (1)	t-hodnota (2)	stupně volnosti	p-val. (2)	F-test
	(bankrot.)	(aktiv.)							(p-val.)
x1	0,277	0,107	0,826	67	0,411573	0,660300	26,956616	0,514665	0,000000
x2	0,322	0,399	-0,438	56	0,663234	-0,426244	33,439414	0,672661	0,671263
x3	-1,081	0,061	-1,591	66	0,116310	-1,168021	23,005687	0,254761	0,000000
x4	6,624	0,505	1,479	57	0,144557	1,050595	19,002160	0,306623	0,000000
x5	3,266	14,929	-0,822	56	0,414410	-1,130591	53,093150	0,263309	0,000012
x6	5,946	0,226	1,337	55	0,186609	0,937256	18,005803	0,361029	0,000000
x7	0,802	-0,066	1,763	61	0,082979	1,262496	20,567252	0,220898	0,000000
x8	1,052	-0,222	2,873	55	0,005769	1,964523	17,314154	0,065727	0,000000
x9	0,081	-0,022	2,602	51	0,012093	2,479971	18,928732	0,022716	0,629600

U Slefendorfas modelu vyhodnotil t-test jako významný jeden ukazatel z devíti. Jedná se o poslední ukazatel x9, který je dosáhl významnosti na 5% úrovni.

Tabulka níže zachycuje t-test u **Brezigar-Masten, Masten modelu**.

Tab. 27: Brezigar-Masten, Masten model - t-test

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Proměnná	průměr	průměr	t-hodnota	stupně volnosti	p-val. (1)	t-hodnota (2)	stupně volnosti	p-val. (2)	F-test
	(bankrot.)	(aktiv.)							(p-val.)
cf2d (=CF/CL)	-1.043	0.407	-2.558	58	0.013163	-1.671	17.143	0.112829	0.000000
kol (=TA/CL)	1.558	3.957	-4.749	67	0.000011	-5.563	58.905	0.000001	0.000009
pppo (=OR/OC)	0.908	1.047	-3.390	67	0.001177	-2.751	28.016	0.010291	0.000000
Tfs (=TL/TA)	66.838	0.470	1.379	68	0.172547	1.088	26.000	0.286745	0.000000

V případě Brezigar-Masten, Masten modelu byli dva ze čtyř ukazatelů vyhodnoceny jako významné. Ukazatel kol (=TA/CL) dosahuje významnosti na úrovni 1 % a ukazatel pppo (=OR/OC) dosahuje významnosti 5% úrovni.

T-test provedený u **Global modelu** lze vidět v následující tabulce.

Tab. 28: Global model – t-test

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Proměnná	průměr	průměr	t-hodnota	stupně volnosti	p-val. (1)	t-hodnota (2)	stupně volnosti	p-val. (2)	F-test
	(bankrot.)	(aktiv.)							(p-val.)
V3 (=NWC/TA)	-3.626	0.318	-1.335	68	0.186436	-1.053	26.003	0.302017	0.000000
V5 (=EBIT/TA)	-224.865	0.070	-1.270	68	0.208513	-1.002	26.000	0.325702	0.000000
V9 (=CA/TA)	0.661	0.616	0.735	68	0.464917	0.671	40.442	0.505848	0.017326

U Global modelu nebyl žádný z ukazatelů vyhodnocen jako významný.

Následující tabulka zachycuje t-test pro **Beerman model**.

Tab. 29: Beerman model - t-test

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Proměnná	průměr	průměr	t-hodnota	stupně volnosti	p-val. (1)	t-hodnota (2)	stupně volnosti	p-val. (2)	F-test
	(bankrot.)	(aktiv.)							(p-val.)
x1	959,6	9687,186	-3,82806	59	0,000315	-4,72777	52,84144	0,000017	0,016701
x2	2,8	0,394	2,27923	57	0,026417	1,44750	15,55097	0,167617	0,000000
x3	-2,3	0,031	-1,56694	67	0,121839	-1,21257	25,00383	0,236628	0,000000
x4	0,3	0,155	1,20005	67	0,234347	1,01912	31,60102	0,315885	0,000012
x5	0,4	0,198	1,79174	67	0,077691	1,41677	26,28180	0,168296	0,000000
x6	-0,3	0,331	-3,35068	59	0,001410	-2,32344	18,28219	0,031873	0,000000
x7	491,5	0,374	1,46685	56	0,148012	1,01416	18,00000	0,323944	0,000000
x8	-226,7	0,061	-1,26972	68	0,208511	-1,00174	26,00000	0,325701	0,000000
x9	26,9	1,517	1,30062	68	0,197779	1,02613	26,00093	0,314281	0,000000
x10	0,0	0,260	-2,75377	56	0,007929	-2,73021	35,00573	0,009841	0,866089

V případě Beerman modelu byly tři z celkových desíti ukazatelů vyhodnoceny jako významné. Ukazatele x1 a x10 dosahují významnosti na úrovni 1 % a ukazatel x6 na úrovni 5 %.

4 NÁVRH VLASTNÍHO BANKROTNÍHO MODELU

Tato část diplomové práce se zabývá tvorbou nového modelu, který je sestaven pomocí logit analýzy. Pro tvorbu modelu byl využit vzorek dat českých společností ze zpracovatelského průmyslu. Tato data byla čerpána z databáze Amadeus. Model byl sestaven pomocí programu IBM SPSS Statistics.

4.1 Tvorba vlastního modelu

V prvním kroku došlo k náhodnému rozdělení vybraného vzorku dat na trénovací (70 %) a testovací (30 %) množinu. Trénovací množina zahrnuje celkem 66 společností, z toho 33 bankrotních a 33 aktivních. Testovací množina disponuje 22 společnostmi, z čehož je 11 bankrotních a 11 aktivních.

V dalším kroku byla zjišťována vzájemná korelace mezi jednotlivými ukazateli, jejichž výčet lze nalézt v následujících tabulkách. V tabulce č. 30 je zobrazen přehled všech ukazatelů Generického modelu.

Tab. 30: Generický model - přehled ukazatelů
(Zdroj: Vlastní zpracování)

Generický model	
X1	provozní cash flow / krátkodobé závazky
X2	$(\text{provozní cash flow} + \text{nákl. úroky} + \text{daň z příjmu}) / \text{nákl. úroky}$
X3	provozní cash flow / tržby
X4	provozní cash flow / aktiva celkem
X5	EBIT / provozní cash flow

Seznam všech ukazatelů Slefendorfas modelu společně s jejich výpočty je vyobrazen v následující tabulce.

Tab. 31: Slefendorfas model - přehled ukazatelů

(Zdroj: Vlastní zpracování)

Slefendorfas model	
X1	$\frac{\text{tržby}_t - \text{tržby}_{t-1}}{\text{tržby}_{t-1}}$
X2	$\frac{\text{provozní náklady}_{t-3} - \text{provozní náklady}_{t-4}}{\text{provozní náklady}_{t-4}}$
X3	$\frac{\text{provozní zisk}_t}{\text{tržby}_t}$
X4	$\frac{\text{celkové závazky}_{t-4}}{\text{aktiva celkem}_{t-4}}$
X5	$\frac{\text{čistý zisk}_{t-5}}{\text{vlastní kapitál}_{t-5}}$
X6	$\frac{\frac{\text{aktiva celkem}_t}{\text{celkové závazky}_t} - \frac{\text{aktiva celkem}_{t-4}}{\text{celkové závazky}_{t-4}}}{\frac{\text{aktiva celkem}_{t-4}}{\text{celkové závazky}_{t-4}}}$
X7	$\frac{\frac{\text{vlastní kapitál}_t}{\text{celkové závazky}_t} - \frac{\text{vlastní kapitál}_{t-2}}{\text{celkové závazky}_{t-2}}}{\frac{\text{vlastní kapitál}_{t-2}}{\text{celkové závazky}_{t-2}}}$
X8	$\frac{\frac{\text{finanční a investiční náklady}_{t-2}}{\text{tržby}_{t-2}} - \frac{\text{finanční a investiční náklady}_{t-4}}{\text{tržby}_{t-4}}}{\frac{\text{finanční a investiční náklady}_{t-4}}{\text{tržby}_{t-4}}}$
X9	$\frac{\frac{\text{provozní náklady}_{t-2}}{\text{tržby}_{t-2}} - \frac{\text{provozní náklady}_{t-5}}{\text{tržby}_{t-5}}}{\frac{\text{provozní náklady}_{t-5}}{\text{tržby}_{t-5}}}$

Následující tabulka zachycuje přehled ukazatelů Brezigar-Masten, Masten modelu.

Tab. 32: Brezigar-Masten, Masten model - přehled ukazatelů
(Zdroj: Vlastní zpracování)

Brezigar-Masten, Masten model	
tfs	celkové závazky/celková aktiva
pppo	provozní výnosy/provozní náklady
kol	celková aktiva/krátkodobé závazky
cf2d	cash flow/krátkodobé závazky
ds	EAT/celková aktiva
kd	vlastní kapitál/celkové závazky
D1	1 když $ds > -0.038$; = 0 v opačném případě
D2	1 když $kd > 0.328$; = 0 v opačném případě

Tabulka s ukazateli pro Global model je znázorněna níže.

Tab. 33: Global model - přehled ukazatelů
(Zdroj: Vlastní zpracování)

Global model	
V3	pracovní kapitál / aktiva celkem
V5	EBIT / aktiva celkem
V9	oběžná aktiva / aktiva celkem

Následující tabulka zachycuje výčet všech ukazatelů Beerman modelu.

Tab. 34: Beerman model - přehled ukazatelů
(Zdroj: Vlastní zpracování)

Beerman model	
X1	odpisy DHM
X2	přírůstek DHM / odpisy DHM
X3	zisk před zdaněním / tržby
X4	závazky vůči bankám / tržby
X5	zásoby / tržby
X6	cash flow / celkové dluhy
X7	celkové dluhy / aktiva
X8	zisk před zdaněním / aktiva celkem
X9	tržby / aktiva celkem
X10	zisk před zdaněním / celkové dluhy

Byla využita Spearmanova korelační analýza v programu IBM SPSS Statistics. Z celkového počtu 33 ukazatelů vykazovalo vzájemnou korelaci vyšší než 0,8 celkem

8 ukazatelů. Tyto ukazatele byly následně vyřazeny. Po vyřazení vysoce korelovaných ukazatelů došlo k sestavování nového modelu. Žádné z dosažených výsledků však nevykazovaly významné hodnoty, proto bylo nutné zvolit jiný postup.

Dále byly zohledněny výsledky t-testu proměnných vybraných bankrotních modelů. Proměnné, které byly při t-testu vyhodnoceny jako významné, byly využity pro sestavení nového modelu. Konkrétně se jednalo o následující proměnné: **CF/CL** (Generický model), **kol** a **pppo** (Brezigar-Masten, Masten model), **x9** (Slefendorfas model), **x1**, **x6** a **x10** (Beerman model).

V programu IBM SPSS Statistics byla použita metoda krokové logistické regrese Forward Stepwise (Wald). Detaily odvozeného modelu jsou zaznamenány v následujících tabulkách. První z nich vyjadřuje celkovou významnost modelu.

Tab. 35: Omnibus test

(Zdroj: Vlastní zpracování pomocí IBM SPSS)

		Chi-square	df	Sig.
Step 1	Step	17,599	1	,000
	Block	17,599	1	,000
	Model	17,599	1	,000
Step 2	Step	7,021	1	,008
	Block	24,620	2	,000
	Model	24,620	2	,000
Step 3	Step	4,320	1	,038
	Block	28,940	3	,000
	Model	28,940	3	,000

Omnibus test zkoumá, zda je v modelu alespoň jedna proměnná, která je statisticky významná. Nově sestavený model dosáhl významnosti na úrovni 1 %, což značí jeho spolehlivost.

Následující tabulka zachycuje kvalitu nově vytvořeného modelu metodou Cox&Snell R Square a Nagelkerke R Square.

Tab. 36: Kvalita nově vytvořeného modelu
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Model Summary			
Step	-2 Log likelihood	Cox & Snell R	Nagelkerke R
		Square	Square
1	35,080 ^a	,371	,494
2	28,059 ^b	,477	,636
3	23,739 ^b	,533	,711

V tabulce lze vidět, že model dosáhl 53,3 % spolehlivosti dle metody hodnocení Cox&Snell R Square. Na základě faktu, že maximální hodnota této metody je nižší než 100 %, je spolehlivost modelu pro interpretaci dále přepočítávána metodou Nagelkerke R Square. V případě této metody dosáhla spolehlivost nově vytvořeného modelu 71,1 %.

V tabulce níže je vyobrazen Hosmer a Lemeshow test, který testuje kvalitu celého modelu.

Tab. 37: Hosmer a Lemeshow test
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Hosmer and Lemeshow Test			
Step	Chi-square	df	Sig.
1	7,562	8	,477
2	4,609	8	,798
3	4,837	8	,775

Ve všech krocích přesáhl model hranici významnosti 5 %, tudíž jej lze dle Hosmer a Lemeshow testu považovat za dobře kalibrovaný model.

Proměnné a jejich významnosti, které byly vybrány pro sestavení nového modelu, jsou znázorněny v následující tabulce.

Tab. 38: Proměnné nového modelu
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

		Variables in the Equation ^d					
		B	S.E.	Wald	df	Sig.	Exp(B)
Step 1 ^a	kol	-,465	,151	9,429	1	,002	,628
Step 2 ^b	kol	-,537	,184	8,485	1	,004	,585
	x9	11,142	5,215	4,564	1	,033	69034,173
Step 3 ^c	kol	-,665	,231	8,290	1	,004	,514
	x9	13,760	6,565	4,393	1	,036	946413,452
	Ber 17 x2	,218	,164	1,785	1	,182	1,244

Ze všech proměnných, které byly pomocí t-testu vyhodnoceny jako významné, byly vybrány 3: kol (Brezingar-Masten, Masten), x9 (Slefendorfas) a x2 (Beerman). Ukazatel kol dosáhl významnosti na 1% úrovni. Ukazatel x9 byl vyhodnocen také jako významný, avšak na úrovni 5 %. Poslední z ukazatelů x2 z Beermanova modelu nebyl vyhodnocen jako významný.

Na základě výsledků krokové logistické regrese byla sestavena rovnice nového modelu:

$$p(\mathbf{B}) = \frac{1}{1 + \exp(-0,665\mathbf{X}_1 + 13,76\mathbf{X}_2 + 0,182\mathbf{X}_3)}$$

Kde:

$$\mathbf{X}_1 \cong kol$$

$$\mathbf{X}_2 \cong X_9$$

$$\mathbf{X}_3 \cong X_2$$

První ukazatel \mathbf{X}_1 (kol) představuje podíl celkových aktiv a krátkodobých závazků.

Ukazatel \mathbf{X}_2 , který odpovídá ukazateli \mathbf{X}_9 Slefendorfas modelu, je dán následující rovnicí:

$$\mathbf{X}_9 = \frac{\frac{\text{provozní náklady}_{t-2}}{\text{tržby}_{t-2}} - \frac{\text{provozní náklady}_{t-5}}{\text{tržby}_{t-5}}}{\frac{\text{provozní náklady}_{t-5}}{\text{tržby}_{t-5}}}$$

Poslední ukazatel X_3 představuje podíl přírůstku dlouhodobého hmotného majetku a jeho odpisů.

Jako cut-off score byla stanovena hranice 0,4:

$p(B) > 0,4$ společnost je ohrožena bankrotem

$p(B) < 0,4$ společnost je aktivní, není ohrožena bankrotem

Po vytvoření nového modelu byla testována jeho přesnost, stejně jako u pěti vybraných bankrotních modelů. Testování přesnosti bylo provedeno zvlášť na trénovacím a testovacím vzorku dat.

4.2 Přesnost modelu na trénovacím vzorku dat

Přesnosti správného zařazení bankrotních a aktivních společností nově vytvořeného modelu na původním (trénovacím) vzorku dat zachycují následující tabulky.

Tab. 39: Přesnost bankrotních společností na trénovacím vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

BANKROTNÍ SPOLEČNOSTI	
	T-1
počet správně zařazených ($>0,4$)	5
počet nesprávně zařazených ($<0,4$)	2
celkový počet	7
přesnost	71,43 %


Tabulka výše obsahuje přesnost správného zařazení bankrotních společností. V tomto případě dosáhla přesnost nového modelu hodnoty 71,43 % na trénovacím vzorku dat. Správně bylo zařazeno 5 ze 7 bankrotních společností. K nesprávnému zařazení došlo ve dvou případech.

Tab. 40: Přesnost aktivních společností na trénovacím vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

AKTIVNÍ SPOLEČNOSTI	
	T-1
počet správně zařazených (<0,4)	27
počet nesprávně zařazených (>0,4)	2
celkový počet	29
přesnost	93,10 %

Přesnost správného zařazení aktivních společností zachycuje tabulka výše. Při klasifikaci aktivních společností dosáhl nově vytvořený model lepšího výsledku než v případě bankrotních společností. Hodnota přesnosti dosáhla 93,10 %. Správně bylo zařazeno 27 z 29 aktivních společností. K nesprávné klasifikaci došlo stejně jako v předchozím případě pouze u dvou společností.

Grafické vyjádření absolutní četnosti správného a nesprávného zařazení bankrotních a aktivních společností lze vidět níže.



Graf 16: Absolutní četnost přesností bankrotních a aktivních společností na trénovacím vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Značný vliv na pozitivnější výsledky v případě aktivních společností měla velikost daného vzorku, kdy celkový počet aktivních společností více než čtyřnásobně převýšil celkový počet bankrotních.

Tab. 41: Celková přesnost modelu na trénovacím vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

CELKOVÁ PŘESNOST	
	T-1
počet správně zařazených	32
počet nesprávně zařazených	4
celkový počet	36
přesnost	88,89 %

Celková přesnost nově vytvořeného modelu na trénovacím vzorku dat dosáhla výrazně pozitivní hodnoty 88,89 %. Správně bylo klasifikováno 32 společností z celkového počtu 36.

4.3 Přesnost modelu na testovacím vzorku dat

Dále bylo provedeno testování přesnosti nově vytvořeného modelu na testovacím vzorku dat, tedy na datech společností, které nebyly zahrnuty do vytváření samotného modelu.

Tab. 42: Přesnost bankrotních společností na testovacím vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

BANKROTNÍ SPOLEČNOSTI	
	T-1
počet správně zařazených (>0,4)	2
počet nesprávně zařazených (<0,4)	1
celkový počet	3
přesnost	66,67 %


Přesnost správného zařazení bankrotních společností v případě testovacího vzorku dat je znázorněna v tabulce výše. Správně byly klasifikovány 2 z 3 bankrotních společností a přesnost modelu v tomto případě dosáhla hodnoty 66,67 %. Tato přesnost byla značně ovlivněna velice malým vzorkem bankrotních společností.

Tab. 43: Přesnost aktivních společností na testovacím vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

AKTIVNÍ SPOLEČNOSTI	
	T-1
počet správně zařazených (<0,4)	8
počet nesprávně zařazených (>0,4)	2
celkový počet	10
přesnost	80,00 %

V případě správného zařazení aktivních společností dosáhla přesnost modelu opět pozitivnějších výsledků než v případě bankrotu. V testovacím vzorku dat bylo správně zařazeno 8 z 10 aktivních společností a přesnost tak nabyla hodnoty 80 %.

Absolutní četnost přesností pro bankrotní a aktivní společnosti je graficky znázorněna níže.



Graf 17: Absolutní četnost přesností bankrotních a aktivních společností na testovacím vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Následující tabulka zachycuje celkovou přesnost modelu.

Tab. 44: Celková přesnost modelu na testovacím vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

CELKOVÁ PŘESNOST	
	T-1
počet správně zařazených	10
počet nesprávně zařazených	3
celkový počet	13
přesnost	76,92 %

Celková přesnost nově vytvořeného modelu testovaná na testovacím vzorku dat dosáhla hodnoty 76,92 %.

4.4 Srovnání přesností trénovacího a testovacího vzorku dat

Na základě předchozích výsledků bylo provedeno celkové srovnání přesností trénovacího a testovacího vzorku dat.


Tab. 45: Srovnání přesností trénovacího a testovacího vzorku dat
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

SROVNÁNÍ PŘESNOSTÍ		
	trénovací vzorek	testovací vzorek
bankrotní	71,43 %	66,67 %
aktivní	93,10 %	80,00 %
celková přesnost	88,89 %	76,92 %

Jak lze pozorovat v tabulce výše, přesnost nově vytvořeného modelu dosahuje vyšších hodnot v případě trénovacího vzorku. Nejlepšího výsledku dosáhl model v případě správného zařazení aktivních společností v trénovacím vzorku dat. Nejnižší hodnoty dosáhla přesnost modelu v případě správné klasifikace bankrotních společností v testovacím vzorku. Jak již bylo zmíněno výše, tato hodnota byla značně ovlivněna nízkým celkovým počtem bankrotních společností. Lze však konstatovat, že přesnost modelu nabývá pozitivních výsledků v obou případech vzorků dat.

4.5 ROC křivky sestaveného modelu

Následující graf zobrazuje ROC křivku nově sestaveného modelu na trénovacím vzorku dat.



Graf 18: ROC křivka – trénovací vzorek
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Níže je zobrazena hodnota plochy pod křivkou a její významnost.

Tab. 46: Plocha pod křivkou – trénovací vzorek
(Zdroj: Vlastní zpracování pomocí IBM SPSS)


Area Under the Curve				
Test Result Variable(s): p(b) L				
Area	Std. Error ^a	Asymptotic Sig. ^b	Asymptotic 95% Confidence Interval	
			Lower Bound	Upper Bound
,867	,079	,003	,713	1,000

a. Under the nonparametric assumption

b. Null hypothesis: true area = 0.5

Jak lze rozpoznat už z grafu výše, nový model dosáhl velice pozitivních výsledků. Hodnota plochy pod křivkou, která byla otestována na trénovacím vzorku dat, dosáhla hodnoty 0,867. Její významnost je na úrovni 1 %, proto ji lze považovat za významnou.

Graf níže zachycuje ROC křivku pro testovací vzorek dat.



Graf 19: ROC křivka – testovací vzorek
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Hodnota plochy pod křivkou a její významnost pro testovací vzorek je zobrazena v následující tabulce.

Tab. 47: Plocha pod křivkou – testovací vzorek
(Zdroj: Vlastní zpracování pomocí IBM SPSS)

Area Under the Curve				
Test Result Variable(s): p(b) T				
Area	Std. Error ^a	Asymptotic Sig. ^b	Asymptotic 95% Confidence Interval	
			Lower Bound	Upper Bound
,767	,152	,176	,468	1,000

a. Under the nonparametric assumption

b. Null hypothesis: true area = 0.5

Hodnota plochy pod křivkou u testovacího vzorku dosahuje podobně pozitivních výsledků jako u trénovacího vzorku. Nabývá hodnoty 0,767. V tomto případě však tato hodnota nenabývá statistické významnosti.

5 SROVNÁNÍ EFEKTIVNOSTI VYTVOŘENÉHO MODELU A VYBRANÝCH MODELŮ

Na základě výsledků testovaných přesností vybraných bankrotních modelů lze konstatovat, že nejlépe obstál Beerman model, jehož hodnota přesností přesáhla u bankrotních i aktivních společností hodnotu 98 %. Jeho celková přesnost tak dosáhla hodnoty 98,59 %.

Jako druhý nejlepší z testovaných modelů byl vyhodnocen Generický model, jehož hodnota přesnosti dosáhla 79,25 % v případě bankrotních společností, a 69,81 % v případě správné klasifikace aktivních společností. Jeho celková přesnost nabývá hodnoty 76,89 %.

U Slefendorfas modelu nedosáhla přesnost výrazně pozitivních výsledků. V případě správné klasifikace bankrotních společností dosáhla hodnoty 54,55 %, v opačném případě 62,12 %.

V případě Brezigar-Masten, Masten modelu dosáhla sice přesnost správného zařazení aktivních společností výrazně pozitivní hodnoty 96,15 %, avšak u bankrotních společností vykazuje nízkou hodnotu přesnosti 42,57 %.

Nejhorších výsledků ze všech testovaných modelů dosáhl Global model, jehož celková přesnost dosáhla hodnoty pouze 39,5 %.

Tab. 48: Srovnání přesností vybraných bankrotních modelů s nově vytvořeným modelem
(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

SROVNÁNÍ PŘESNOSTÍ VYBRANÝCH BANKROTNÍCH MODELŮ S NOVĚ VYTVOŘENÝM MODELEM							
Model	Nový - trénovací	Nový - testovací	Generic	Slefendorfas	Brezigar- Masten	Global	Beerman
bankrotní	71,43 %	66,67 %	79,25 %	54,55 %	42,57 %	85,71 %	98,31 %
aktivní	93,10 %	80,00 %	69,81 %	62,16 %	96,15 %	14,49 %	98,70 %
celková přesnost	88,89 %	76,92 %	76,89 %	60,42 %	57,50 %	39,50 %	98,59 %

Při porovnávání přesností vybraných bankrotních modelů s nově vytvořeným modelem lze říci, že nově vytvořený model dosáhl druhé nejvyšší celkové přesnosti. Přesto, že hodnota přesnosti správného zařazení bankrotních společností klesla

z původních 71,43 % na 66,67 % a hodnota přesnosti u aktivních společností klesla z 93,10 % na 80 % při ověřování na testovacím vzorku, model stále vykazuje velice pozitivní výsledky.

Na základě výsledků přesností testovaných bankrotních modelů a nově vytvořeného modelu a jejich srovnání lze soudit, že pro predikci bankrotu společností působících v oblasti zpracovatelského průmyslu v České republice je vhodné využít kombinaci nově vytvořeného modelu a Beerman modelu. Kombinace těchto dvou modelů zaručí vysokou pravděpodobnost správné klasifikace vybraného vzorku společností.

ZÁVĚR

Bankrotní modely, které jsou využívány k hodnocení finanční situace ve společnosti a predikci jejího vývoje, jsou sestavovány různými metodami. Hlavním úkolem těchto modelů je zařadit vybranou společnost do skupiny bankrotních nebo aktivních společností na základě finančních ukazatelů sestavených z dat účetních výkazů. V historii bylo vytvořeno velké množství takových modelů, které se ve většině případů zaměřovaly na konkrétní zemi nebo odvětví.

Teoretická část této práce definovala základní pojmy spojené s oblastí predikce bankrotu. Následně byly vymezeny nejčastěji používané metody pro tvorbu bankrotních modelů a charakterizovány vybrané bankrotní modely vytvořené v minulosti. Další část teoretické části práce se zaměřila na přesnost, ROC křivky a omezení modelů.

V praktické části práce bylo provedeno zhodnocení současné efektivnosti pěti vybraných bankrotních modelů, kterými byly Generic model, Slefendorfas model, Brezigar-Masten, Masten model, Global model a Beerman model. U všech modelů bylo provedeno testování spolehlivosti na vzorku dat českých společností zpracovatelského průmyslu a následně sestaveny ROC křivky. Nejlepších výsledků ze všech vybraných modelů dosáhl Beerman model, jehož celková přesnost byla vyčíslena na 98,59 % a hodnota plochy pod křivkou nabývala hodnoty 0,869 se statistickou významností na úrovni 1 %. Na základě této skutečnosti lze model považovat za vhodný pro predikci bankrotu v této oblasti. Ostatní modely takto pozitivních výsledků nedosahovaly.

Po testování pěti vybraných bankrotních modelů byl metodou krokové logistické regrese v programu IBM SPSS Statistics sestaven nový model. Tento model byl následně testován odděleně na trénovacím a testovacím vzorku dat. Výsledkem testování na trénovacím vzorku byla přesnost 71,43 % pro bankrotní a 93,10 % pro aktivní společnosti. Celková přesnost modelu v případě trénovacího vzorku dat dosáhla hodnoty 88,89 %. Při následném ověřování na testovacím vzorku dat, tedy na datech společností, které nebyly zahrnuty do sestavování modelu, dosáhla přesnost hodnoty 66,67 % pro bankrotní a 80 % pro aktivní společnosti. Celková přesnost byla vyčíslena na 76,92 %.

Nově sestavený model lze tedy považovat za vhodný pro predikci bankrotu v oblasti zpracovatelského průmyslu v České republice. Je však nutné poznamenat, že byl sestaven na poměrně malém vzorku dat malých a středně velkých společností zpracovatelského průmyslu, proto se jeho vypovídající schopnost může lišit v případě použití v jiném průmyslovém odvětví.

SEZNAM POUŽITÝCH ZDROJŮ

ALAMINOS, David, DEL CASTILLO. Correction: *A Global Model for Bankruptcy Prediction*. *PLoS ONE* [online]. Public Library of Science, 2018, **13**(11) [cit. 2019-01-14]. DOI: 10.1371/journal.pone.0208476

ALTMAN, E. I., 2002: *Bankruptcy, credit, risk, and high yield junk bonds*. Malden: Blackwell. ISBN 0631225633.

BECERRA, V. M., GALVÃO, R. K., & ABOU-SEADA, M. (2005). Neural and wavelet network models for financial distress classification. *Data Mining and Knowledge Discovery*, *11*(1). DOI: 10.1007/s10618-005-1360-0.

BHANDARI, Shyam, JOHNSON-SYDER. *A Generic Model Of Predicting Probability Of Success-Distress Of An Organization: A Logistic Regression Analysis*. *Journal of Applied Business Research* [online]. Laramie: The Clute Institute, 2018, **34**(1), 169-182 [cit. 2019-01-14]. DOI: 10.19030/jabr.v34i1.10107. ISSN 0892-7626. Dostupné z: <http://search.proquest.com/docview/2082228499/>

BREZIGAR-MASTEN, Arjana, MASTEN. *CART-based selection of bankruptcy predictors for the logit model*. *Expert Systems With Applications* [online]. Elsevier, 2012, **39**(11), 10153-10159 [cit. 2019-01-14]. DOI: 10.1016/j.eswa.2012.02.125. ISSN 0957-4174.

Brief history of bankruptcy. *Bankruptcy data: a division of new generation* [online]. 2016 [cit. 2018-11-19]. Dostupné z: <https://www.bankruptcydata.com/p/briefhistory-of-bankruptcy>.

ČÁMSKÁ, D. *Bankrotní modely tranzitivních zemí*. *Trendy v podnikání* [online]. 2012, s. 12 [cit. 2017-02-15]. ISSN 1805-0603. Dostupné z: <https://otik.uk.zcu.cz/bitstream/11025/16238/1/Camska.pdf>

FAWCETT, Tom. An introduction to ROC analysis. *Pattern Recognition Letters* [online]. 2006, č. 8, 861-874 [cit. 2018-12-11]. DOI: 10.1016/j.patrec.2005.10.010. ISSN 01678655. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S016786550500303X>.

FEJÉR-KIRÁLY, Gergely. *Bankruptcy Prediction: A Survey on Evolution, Critiques, and Solutions*. Acta Univ. Sapientiae, Economics and Business. 2015, (3), 93-108. DOI: 10.1515/auseb-2015-0006.

GRICE, J. S., DUGAN, M. T. The limitations of bankruptcy prediction models: Some cautions for the researchers. *Review of Quantitative Finance and Accounting*. 2001, vol. 17, pp. 151-166. ISSN 1573-7179.

HENDL, Jan, 2012. *Přehled statistických metod: analýza a metaanalýza dat*. 4., rozš. vyd. Praha: Portál. ISBN 978-80-262-0200-4.

HOSMER, David W a Stanley LEMESHOW, 2000. *Applied logistic regression*. 2nd ed. New York: John Wiley. ISBN 0-471-35632-8.

JANÍČEK, Přemysl a Jiří MAREK, 2013. *Expertní inženýrství v systémovém pojetí*. Praha: Grada. Expert (Grada). ISBN 978-80-247-4127-7.

KAPLINSKI, O. *Usefulness and Credibility of Scoring Methods in Construction Industry*. *Journal of Civil Engineering and Management*, 2008. ISSN 1392-3730.

LIANG, Deron, Chih-Fong TSAI a Hsin-Ting WU, 2015. *The effect of feature selection on financial distress prediction*. *Knowledge-Based Systems*. 73, 289-297. DOI: 10.1016/j.knosys.2014.10.010. ISSN 09507051.

NÝVLTOVÁ, Romana a Pavel MARINIČ. *Finanční řízení podniku: moderní metody a trendy*. Praha: Grada, 2010. Prosperita firmy. ISBN 978-80-247-3158-2.

PREMACHANDRA, I.M., Gurmeet Singh BHABRA a Toshiyuki SUEYOSHI. DEA as a tool for bankruptcy assessment: A comparative study with logistic regression technique. *European Journal of Operational Research* [online]. Elsevier B.V, 2009, **193**(2), 412-424 [cit. 2018-11-04]. DOI: 10.1016/j.ejor.2007.11.036. ISSN 0377-2217.

ROBU, Ioan Bogdan a Costel ISTRATE, 2015. *The Analysis of the Principal Components of the Financial Reporting in the Case of Romanian Listed Companies. Procedia Economics and Finance*. 20, 553-561. DOI: 10.1016/S2212-5671(15)00108-2. ISSN 22125671.

ROWE, P. 2015. *Logistic regression. In Essential Statistics for the Pharmaceutical Sciences*, DOI:10.1002/9781119109075.ch20

RŮČKOVÁ, Petra, 2011. *Finanční analýza: metody, ukazatele, využití v praxi*. 4., aktualiz. vyd. Praha: Grada. Finanční řízení. ISBN 978-80-247-3916-8.

SLEFENDORFAS, Gediminas. *Bankruptcy prediction model for private limited companies of lithuania. Ekonomika* [online]. Vilnius: Vilniaus Universiteto Leidykla, 2016, **95**(1), 134-152 [cit. 2019-01-14]. DOI: 10.15388/Ekon.2016.1.9910. ISSN 13921258. Dostupné z: <http://search.proquest.com/docview/1788578029/>

SMEJKAL, Vladimír a Karel RAIS, 2013. *Řízení rizik ve firmách a jiných organizacích*. 4., aktualiz. a rozš. vyd. Praha: Grada. Expert (Grada). ISBN 978-80-247-4644-9.

SYNEK, Miloslav, Heřman KOPKÁNĚ a Markéta KUBÁLKOVÁ, 2009. *Manažerské výpočty a ekonomická analýza*. V Praze: C.H. Beck. Beckova edice ekonomie. ISBN 978-80-7400-154-3.

The magnificent ROC : Receiver operating characteristic curve [online]. 2007 [cit. 2018-10-18]. Dostupné z: <http://www.anaesthetist.com/mnm/stats/roc/Findex.htm>.

TSAI, Chih-Fong, 2009. *Feature selection in bankruptcy prediction*. Knowledge-Based Systems. 22(2), 120-127. DOI: 10.1016/j.knosys.2008.08.002. ISSN 09507051.

VOCHOZKA, M. 2011. *Metody komplexního hodnocení podniku*. Praha: Grada. Finanční řízení. ISBN 978-80-247-3647-1.

Zákon č. 182/2006 Sb. o úpadku a způsobech jeho řešení (insolvenční zákon). In: *Sbírka zákonů*. 30. 3. 2006.

ZANGANEH, Tayebah, Meysam RABIEE a Masoud ZAREI, 2011. *Applying Adaptive Neuro – Fuzzy Model for Bankruptcy Prediction*. International Journal of Computer Applications. 20(3), 15-21.

ZOPOUNIDIS, Constantin. *Multicriteria Decision Aid Methods for the Prediction of Business Failure*. Boston: Kluwer Academic Publishers, 1998. ISBN 07-923-4900-8.

SEZNAM ZKRATEK

AUC	hodnota plochy pod křivkou
CF	cash flow (peněžní tok)
CFO	operativní cash flow
CL	krátkodobé závazky
DHM	dlouhodobý hmotný majetek
EBIT	zisk před zdaněním a úroky
INT	nákladové úroky
NWC	pracovní kapitál
OC	provozní náklady
OR	provozní výnosy
ROC	receiver operating characteristic
TA	celková aktiva
TAX	daň z příjmu
TL	celkové závazky

SEZNAM TABULEK

Tab. 1: Zařazení daného vzorku	33
Tab. 2: Generický model – přesnosti aktivních společností	38
Tab. 3: Generický model – přesnosti bankrotních společností	39
Tab. 4: Generický model - celková přesnost	40
Tab. 5: Generický model - srovnání přesností	41
Tab. 6: Slefendorfas model - přesnost aktivních a bankrotních společností	42
Tab. 7: Slefendorfas model - srovnání přesností	43
Tab. 8: Brezigar-Masten, Masten model - přesnosti aktivních společností	44
Tab. 9: Brezigar-Masten, Masten model - přesnosti bankrotních společností	45
Tab. 10: Brezigar-Masten, Masten model – celková přesnost	46
Tab. 11: Brezigar-Masten, Masten model – srovnání přesností	46
Tab. 12: Globální model - přesnosti aktivních společností	47
Tab. 13: Globální model - přesnosti bankrotních společností	48
Tab. 14: Globální model - celková přesnost	49
Tab. 15: Globální model - srovnání přesností	49
Tab. 16: Beerman model – přesnosti aktivních společností	50
Tab. 17: Beerman model – přesnosti bankrotních společností	51
Tab. 18: Beerman model - celková přesnost	52
Tab. 19: Beerman model - srovnání přesností	52

Tab. 20: Generický model – plocha pod křivkou	54
Tab. 21: Slefendorfas model - plocha pod křivkou	55
Tab. 22: Brezigar-Masten, Masten model - plocha pod křivkou	56
Tab. 23: Global model - plocha pod křivkou.....	57
Tab. 24: Beerman model – plocha pod křivkou.....	58
Tab. 25: Generický model - t-test	58
Tab. 26: Slefendorfas model - t-test.....	59
Tab. 27: Brezigar-Masten, Masten model - t-test	59
Tab. 28: Global model – t-test	59
Tab. 29: Beerman model - t-test	60
Tab. 30: Generický model - přehled ukazatelů.....	61
Tab. 31: Slefendorfas model - přehled ukazatelů	62
Tab. 32: Brezigar-Masten, Masten model - přehled ukazatelů.....	63
Tab. 33: Global model - přehled ukazatelů.....	63
Tab. 34: Beerman model - přehled ukazatelů	63
Tab. 35: Omnibus test.....	64
Tab. 36: Kvalita nově vytvořeného modelu.....	65
Tab. 37: Hosmer a Lemeshow test.....	65
Tab. 38: Proměnné nového modelu	66
Tab. 39: Přesnost bankrotních společností na trénovacím vzorku dat.....	67
Tab. 40: Přesnost aktivních společností na trénovacím vzorku dat.....	68

Tab. 41: Celková přesnost modelu na trénovacím vzorku dat.....	69
Tab. 42: Přesnost bankrotních společností na testovacím vzorku dat	69
Tab. 43: Přesnost aktivních společností na testovacím vzorku dat.....	69
Tab. 44: Celková přesnost modelu na testovacím vzorku dat	70
Tab. 45: Srovnání přesností trénovacího a testovacího vzorku dat	71
Tab. 46: Plocha pod křivkou – trénovací vzorek	72
Tab. 47: Plocha pod křivkou – testovací vzorek.....	73
Tab. 48: Srovnání přesností vybraných bankrotních modelů s nově vytvořeným modelem	74

SEZNAM GRAFŮ

Graf 1: ROC graf	35
Graf 2: Generický model - absolutní četnost přesnosti aktivních společností.....	39
Graf 3: Generický model - absolutní četnost přesnosti bankrotních společností	40
Graf 4: Slefendorfas model – absolutní četnost přesnosti aktivních a bankrotních společností	43
Graf 5: Brezigar-Masten, Masten model – absolutní četnost přesnosti aktivních společností	45
Graf 6: Brezigar-Masten, Masten model – absolutní četnost přesnosti bankrotních společností	46
Graf 7: Globální model – absolutní četnost přesností aktivních společností.....	48
Graf 8: Globální model – absolutní četnost přesností bankrotních společností	49
Graf 9: Beerman model – absolutní četnost přesností aktivních společností	51
Graf 10: Beerman model – absolutní četnost přesností bankrotních společností	52
Graf 11: Generický model - ROC křivka.....	53
Graf 12: Slefendorfas model - ROC křivka	54
Graf 13: Brezigar Masten, Masten model - ROC křivka.....	55
Graf 14: Global model - ROC křivka	56
Graf 15: Beerman model - ROC křivka.....	57
Graf 16: Absolutní četnost přesností bankrotních a aktivních společností na trénovacím vzorku dat	68

Graf 17: Absolutní četnost přesností bankrotních a aktivních společností na testovacím vzorku dat	70
Graf 18: ROC křivka – trénovací vzorek	72
Graf 19: ROC křivka – testovací vzorek	73

SEZNAM PŘÍLOH

Příloha 1: Spearmanova korelace – vyřazené ukazatele s vysokou korelací..... i

Příloha 1: Spearmanova korelace – vyřazené ukazatele s vysokou korelací

(Zdroj: Vlastní zpracování na základě dat z databáze Amadeus)

Spearman's rho	CFO/CL	CFO/TA	tfs	pppo	V5	Ber 17 x3	Ber 17 x6	Ber 17 x8
CFO/CL	1,000	,854**	-,493**	,503**	0,307	,404*	,517**	0,307
(CFO + INT + TAX)/ INT	,725**	,659**	-0,332	0,094	-0,022	0,011	0,338	0,007
CFO/SALES	,869**	,932**	-0,265	,395*	0,162	0,263	0,243	0,127
CFO/TA	,854**	1,000	-0,163	,390*	0,241	0,284	0,250	0,239
EBIT/CFO	-0,047	-0,116	-0,002	0,085	0,217	0,026	0,139	0,199
tfs	-,493**	-0,163	1,000	-,458**	-,404**	-,468**	-,801**	-,445**
pppo	,503**	,390*	-,458**	1,000	,884**	,881**	,815**	,834**
kol	,560**	0,196	-,862**	,443**	,332*	,495**	,723**	,382*
cf2d	,551**	0,315	-,696**	,838**	,759**	,841**	,945**	,790**
D1	0,209	0,198	-,338*	,544**	,544**	,544**	,579**	,544**
D2	,369*	0,207	-,856**	,400**	,388**	,364*	,685**	,402**
V3	-0,113	-,367*	-,358*	0,032	0,001	0,159	0,210	0,039
V5	0,307	0,241	-,404**	,884**	1,000	,811**	,766**	,951**
V9	-0,079	0,014	-0,025	-0,211	-0,007	-0,146	-0,105	0,050
Slef_x1	-0,167	-0,183	0,123	0,038	0,039	0,053	-0,104	-0,006
Slef_x2	-0,356	-0,181	0,264	-0,024	0,131	-0,206	-0,150	-0,032
Slef_x3	0,236	0,013	-,437**	,550**	,434**	,625**	,572**	,465**
Slef_x4	-,512**	-0,128	,843**	-0,295	-0,266	-0,328	-,644**	-,360*
Slef_x5	,382*	0,256	-,415*	0,169	0,025	0,056	0,179	0,015
Slef_x6	0,048	-0,083	-0,348	0,096	0,134	0,134	0,161	0,124
Slef_x7	0,145	0,182	-0,144	0,044	0,122	0,077	-0,004	0,162
Slef_x8	0,014	0,092	0,137	-0,005	-0,155	-0,070	-0,075	-0,228
Slef_x9	-0,070	0,012	0,148	-,456**	-,455**	-0,342	-0,219	-0,347
Ber 17 x1	0,315	0,171	-,417**	,518**	,374*	,423**	,574**	,343*
Ber 17 x2	0,100	0,252	0,102	0,138	0,118	0,034	-0,009	0,050
Ber 17 x3	,404*	0,284	-,468**	,881**	,811**	1,000	,791**	,891**
Ber 17 x4	-0,145	-0,036	0,295	0,145	0,015	0,132	-0,061	-0,038
Ber 17 x5	-0,083	-0,222	-0,104	-0,010	-0,239	0,077	-0,026	-0,191
Ber 17 x6	,517**	0,250	-,801**	,815**	,766**	,791**	1,000	,788**
Ber 17 x7	-0,294	-0,114	,618**	-,448**	-,398*	-,432*	-,568**	-,393*
Ber 17 x8	0,307	0,239	-,445**	,834**	,951**	,891**	,788**	1,000
Ber 17 x9	-0,055	0,128	0,000	-0,098	0,223	-0,115	0,008	0,216
Ber 17 x10	0,192	0,020	-,553**	,807**	,867**	,804**	,783**	,876**

** . Correlation is significant at the 0.01 level (2-tailed).

* . Correlation is significant at the 0.05 level (2-tailed).