



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV FINANCI

INSTITUTE OF FINANCES

MODELOVÁNÍ PREDIKCE BANKROTU MALÝCH A STŘEDNÍCH PODNIKŮ

BANKRUPTCY PREDICTION MODELLING SMALL AND MEDIUM ENTERPRISES

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Valeriia Shmatova

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Michal Karas, Ph.D.

BRNO 2023

Zadání diplomové práce

Ústav: Ústav financí
Studentka: Valeriia Shmatova
Vedoucí práce: doc. Ing. Michal Karas, Ph.D.
Akademický rok: 2022/23
Studijní program: Účetnictví a finanční řízení podniku

Garantka studijního programu 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 bankrotu malých a středních podniků

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 přesnost pěti vybraných bankrotních modelů a její porovnání s původně deklarovanou přesností. A následně vhodnou metodou odvodit vlastní predikční model určený pro malé a střední podniky a testovat přesnost tohoto modelu.

Základní literární prameny:

ALTMAN, E. I. and G. SABATO. Modelling Credit Risk for SMEs: Evidence from the U.S. Market. Abacus. 2007, vol. 43, no. 3, s. 332-357. ISSN 0001-3072.

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, no. 2, s. 151-166. ISSN 1573-7179.

NEUMAIEROVÁ, I., a I. NEUMAIER. Index IN05. In: ČERVINEK, P. (ed.). Evropské finanční systémy. Brno: Masarykova univerzita, 2005. S.143-148. ISBN 80-210-3753-9.

WU, Y., GAUNT, C., GRAY, S. A comparison of alternative bankruptcy prediction models. Journal of Contemporary Accounting & Economics. 2010, vol. 6, pp. 34-45. ISSN 1815-5669

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2022/23

V Brně dne 5.2.2023

L. S.

prof. Ing. Mária Režňáková, CSc.
garantka

doc. Ing. Vojtěch Bartoš, Ph.D.
děkan

Abstrakt

Předložená diplomová práce se zabývá modelováním rizika bankrotu v České republice, včetně jeho příčin a související právní regulace. Teoretická část práce se zaměřuje na bankrotní modely a jejich tvorbu, včetně statistických metod používaných v těchto modelech. V analytické části bylo provedeno testování přesnosti vybraných bankrotních modelů od různých autorů, vytvoření nového bankrotního modelu pomocí logistické regrese na vzorcích malých a středních českých a slovenských podniků v zpracovatelském průmyslu a následné srovnání výkonnosti tohoto nového modelu s ostatními.

Klíčová slova

Bankrot, úpadek, bankrotní model, logistická regrese, ROC křivka, SME, zpracovatelský průmysl.

Abstract

This thesis explores the issue of corporate bankruptcy in the Czech Republic, including its causes and related legal regulation. The theoretical part of the thesis focuses on bankruptcy models and their creation, including the statistical methods used in these models. In the analytical part, the accuracy of selected bankruptcy models from different authors was tested, a new bankruptcy model was created using logistic regression on samples of small and medium-sized Czech and Slovak companies in the manufacturing industry, and the performance of this new model was subsequently compared to others.

Keywords

Bankruptcy, insolvency, bankruptcy model, logistic regression, ROC curve, SME (Small and Medium-sized Enterprises), manufacturing industry.

Bibliografická citace

SHMATOVA, Valeria. *Modelování predikce bankrotu malých a středních podniků* [online]. Brno, 2023 [cit. 2023-05-07]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/152011>. Diplomová práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav financí. Vedoucí práce doc. Ing. Michal Karas, Ph.D.

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 7. 5. 2023

Valeriia Shmatova

autor

Děkuji vedoucímu diplomové práce doc. Ing. Michalovi Karasovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce. Děkuji za trpělivost a porozumění, podporu a Váš čas.

OBSAH

ÚVOD	11
CÍLE PRÁCE, METODY A POSTUPY ZPRACOVÁNÍ.....	13
1 TEORETICKÁ VÝCHODISKA PREDIKCE BANKROTU A POPIS TESTOVANÝCH MODELŮ	14
1.1 Bankrot	14
1.1.1 Vymezení pojmu bankrot vs insolvence.....	14
1.1.2 Příčiny vzniku bankrotu	16
1.1.3 Právní regulace.....	20
1.2 Malé a střední podniky	22
1.2.1 Vymezení	22
1.2.2 Kritéria.....	23
1.2.3 Význam.....	23
1.3 Zpracovatelský průmysl	26
1.3.1 Pojem.....	26
1.3.2 Podíl na celkovém trhu.....	26
1.4 Metody tvorby modelů	28
1.4.1 Lineární diskriminační analýza.....	30
1.4.2 Konkrétní aplikace metody lineární diskriminační analýzy	31
1.4.3 Logit analýza.....	33
1.4.4 Omezení modelů predikce bankrotu	35
1.5 Hodnocení proměnných.....	36
1.5.1 Korelace.....	36
1.5.2 T-test.....	36
1.6 Hodnocení výkonnosti modelu	38
1.6.1 ROC křivka.....	38

1.6.2	Plocha pod křivkou AUC.....	40
1.7	Bankrotní modely.....	41
1.7.1	SME 2 model	43
1.7.2	Model Lugovskaya.....	44
1.7.3	Model Conan & Holder.....	45
1.7.4	Model Gediminas Šlefendorfas	46
1.7.5	Model Tereshchenko	47
2	ZHODNOCENÍ SOUČASNÉ EFEKTIVNOSTI VYBRANÝCH BANKROTNÍCH MODELŮ NA ZKOUMANÉM VZORKU PODNIKŮ	50
2.1	Přesnost modelu SME 2	50
2.2	Přesnost modelu Lugovskaya	52
2.3	Přesnost modelu Conan & Holder	52
2.4	Přesnost modelu Gediminas Šlefendorfas	53
2.5	Přesnost modelu Tereshchenko	54
2.6	ROC křivky vybraných modelů	54
2.6.1	ROC křivka modelu SME 2.....	55
2.6.2	ROC křivka modelu Lugovskaya.....	56
2.6.3	ROC křivka modelu Conan & Holder.....	57
2.6.4	ROC křivka modelu Gediminas Šlefendorfas	58
2.6.5	ROC křivka modelu Tereshchenko	59
2.7	T-test vybraných proměnných.....	60
2.7.1	T-test ukazatele modelu SME 2	61
2.7.2	T-test ukazatele modelu Lugovskaya	62
2.7.3	T-test ukazatele modelu Conan & Holder	63
2.7.4	T-test ukazatele modelu Gediminas Šlefendorfas	64
2.7.5	T-test ukazatele modelu Tereshchenko	64

3 NÁVRH VLASTNÍHO BANKROTNÍHO MODELU	65
3.1 Korelační analýza.....	65
3.2 Logistická regrese	68
3.2.1 Model 1.....	70
3.2.2 Model 2.....	71
3.2.3 Model 3.....	72
3.2.4 Model 4.....	73
3.2.5 Model 5.....	74
3.3 ROC křivka sestavených modelů na trénovacích vzorcích	75
3.4 ROC křivka sestavených modelů na testovacích vzorcích.....	76
3.5 Přesnost sestavených modelů na základě trénovacích vzorků.....	77
3.6 Přesnost sestavených modelů na základě testovacích vzorků	78
4 SROVNÁNÍ EFEKTIVNOSTI VYTVOŘENÉHO MODELU A VYBRANÝCH MODELŮ.....	80
ZÁVĚR	81
SEZNAM POUŽITÝCH ZDROJŮ	83
SEZNAM POUŽITÝCH ZKRATEK	88
SEZNAM POUŽITÝCH OBRÁZKŮ.....	89
SEZNAM POUŽITÝCH TABULEK.....	90
SEZNAM POUŽITÝCH GRAFŮ	92

ÚVOD

V podmírkách tržní ekonomiky a při zohlednění řady vnějších i vnitřních faktorů, které ovlivňují činnost tuzemských podniků, je možné sledovat negativní trend u takových ukazatelů, jako je rentabilita, platební schopnost či finanční stabilita podniků. Všechny ukazují, jak stabilní a flexibilní může být podnik vůči vlivu různých faktorů a podmínek v ekonomice.

Relevantnost tématu práce je dána tím, že krizové jevy v ekonomice České republiky mají přímý dopad na činnost podniků v tomto prostředí. V souvislosti s finanční krizí je problém bankrotu pro podnikatelské subjekty poměrně aktuální a vyznačuje se velkým poklesem objemů výroby v různých odvětvích ekonomiky, poklesem finanční stability a růstem počtu zkrachovalých podniků. Mechanismus obnovení platební schopnosti dlužníka či prohlášení jeho bankrotom je klíčový při řešení problematických otázek zadluženosti a finanční sanace podniků, zachování pracovních míst a výrobního potenciálu.

Nejvíce citlivé ke změnám v ekonomice a projevem krize jsou male a střední podniky ve zpracovatelském průmyslu, proto v diplomové práci byl kladen důraz na tuto skupinu podniků v České republice a Slovenské republice. Slovenská republika byla vybrána z důvodu zvýšení počtu vzorků pro tvorbu modelu a jsou k dispozici spolehlivá a dostupná data o hospodářské činnosti firem, což usnadňuje tvorbu bankrotních modelů. V obou zemích existují obdobné právní předpisy a regulace, což usnadňuje srovnání podnikatelského prostředí a finančních ukazatelů.

Cílem vytvoření modelu pro predikci bankrotu podniku je identifikovat podniky, které mají vysokou pravděpodobnost bankrotu v blízké budoucnosti. Účelem modelu je umožnit investorům, věřitelům, manažerům a dalším zainteresovaným stranám posoudit riziko spojené s investicí nebo spoluprací s konkrétním podnikem. Model by měl být schopen využít historická finanční data a další relevantní informace k predikci bankrotu a poskytnout užitečnou informaci pro rozhodování.

V teoretické části diplomové práce se budeme věnovat vymezení pojmu bankrot. Důležitým krokem k zabránění bankrotu je porozumět faktorům, které mohou vést k tomuto stavu, a jak jim předejít. V této části se také podrobněji zaměříme na právní regulace, především na Insolvenční zákon, který v České republice řeší insolvenční řízení.

Vymezeny budou také klíčové pojmy, jako jsou malé a střední podniky a zpracovatelský průmysl. Dále budou představeny různé druhy bankrotních modelů, včetně jejich konceptu, metod tvorby a hodnocení.

V praktické části diplomové práce bude provedena analýza přesnosti vybraných bankrotních modelů od různých autorů. Výsledky těchto analýz poslouží jako inspirace pro vytvoření vlastního modelu s využitím statistické metody logistické regrese. V závěrečné části bude porovnána výkonnost vlastního modelu s vybranými modely a bude provedeno zhodnocení jeho účinnosti.

CÍLE PRÁCE, METODY A POSTUPY ZPRACOVÁNÍ

Cílem práce je zhodnotit přesnost pěti vybraných bankrotních modelů a její porovnání s původně deklarovanou přesností. A následně vhodnou metodou odvodit vlastní predikční model určený pro malé a střední podniky a testovat přesnost tohoto modelu.

Metody zpracování práce:

- Literární rešerše byla použita při napsání teoretické části diplomové práce (1).
- Analýza byla použita v teoretické části jako rozbor zkoumaného teoretického materiálu pro hlubší poznání tématu (1).
- Syntéza je výsledkem předchozích metod a zahrnuje sjednocení zkoumaného materiálu do jednoho celku v teoretické a praktické části (1).
- Srovnávání bankrotních modelů, proměnných a hodnocení přesnosti modelů bylo provedeno v teoretické a praktické části (1).
- Matematické a statistické metody byly využity výhradně v analytické části, například korelační analýza, t-test atd (1).
- Měření – hodnocení modelů na základě ROC křivek v praktické části (1).
- Modelování bylo použito při tvorbě vlastního modelu v analytické části diplomové práce (1).

Postupy zpracování:

- Popis problematiky bankrotu podniku, bankrotních modelů a jejich tvorby v teoretické části.
- Stanovení přesnosti jednotlivých modelů na základě počítání, hodnocení pomocí ROC křivek a plochy pod křivkou AUC.
- Výběr a zhodnocení proměnných vybraných modelů, jejich významnosti pro použití při tvorbě vlastního modelu pomocí korelační analýzy a t-testu.
- Tvorba vlastního modelu na základě vybraných proměnných pomocí logistické regrese analýzy v statistickém programu.
- Srovnání vytvořeného modelu s ostatními a hodnocení jeho přesnosti.

1 TEORETICKÁ VÝCHODISKA PREDIKCE BANKROTU A POPIS TESTOVANÝCH MODELŮ

V první kapitole diplomové práce se budeme zabývat pojmem bankrot, insolvence a úpadek, jejich rozdíly. Pro snahu zamezit stavu bankrotu podniku je důležité porozumět příčinám vzniku tohoto stavu a čím může být způsoben. Také se podíváme na právní regulace. Nejdůležitějším zdrojem informací je Insolvenční zákon. Pro účely diplomové práci budou vymezeny pojmy, jako jsou malé a střední podniky a zpracovatelský průmysl. Budou uvedeny různé druhy bankrotních modelů, jejich ponětí, metody tvorby modelů a hodnocení.

1.1 Bankrot

1.1.1 Vymezení pojmu bankrot vs insolvence

Bankrot (úpadek) – uznáný soudním příkazem stav jako absolutní platební neschopnost a finanční neschopnost dlužníka pokračovat v podnikatelské činnosti, uspokojovat požadavky věřitelů a plnit své závazky v souvislosti s neuspokojivou ekonomickou situací, jejímž důsledkem je hluboká finanční krize, a stavem, který je právním základem pro likvidaci podniku (2,3).

Nejprve lze začít s definováním finanční tísni firem, která může být předpokladem jejich úpadku. Je nutné upozornit, že finanční tíseň není totéž, co bankrot, ale může být jeho příznakem. Taková situace nemusí v případě provedení nezbytných opatření skončit úpadkem (4).

Finanční tíseň je jedním z nejdůležitějších ukazatelů úpadku; proto se jím zabýváme v následujícím textu. Altman a Hotchkiss v literatuře (4) definovali pojem finanční tísni a poukázali na to, že bankrot představuje právní konec finanční tísni. Hendel používá pravděpodobnostní přístup a definuje finanční tíseň jako pravděpodobnost bankrotu, která závisí na výši likvidních aktiv a také na dostupnosti úvěru. Hypotézou Platta (5) je, že „finanční tíseň je něco, co se společnostem stává v důsledku provozních rozhodnutí nebo vnějších sil, zatímco bankrot je něco, co se společnosti rozhodnou udělat, aby ochránily svá aktiva před věřiteli“.

Finanční krize nastává, když firma není schopna dostát svým finančním závazkům kvůli poklesu obchodní aktivity firmy, nelikvidním aktivům a vysokým fixním nákladům. Naproti tomu bankrot je konečný stav, ve kterém firmy přestanou podnikat kvůli této finanční tísni. V některých případech lze finanční tíseň odhalit dříve, než se společnost dostane do platební neschopnosti. Proto finanční tíseň ne vždy vede k bankrotu (4).

Altman v roce 1971 (6) byl mezi prvními, kdo rozlišoval mezi pojmy „úpadek“, „insolvence“ a „bankrot“. Termín úpadek znamená neschopnost dosáhnout adekvátní návratnosti investice. Společnost může fungovat několik let, než ukončí svou obchodní činnost. Insolvence znamená, že společnost nemůže hradit své závazky v době jejich splatnosti, což může být dočasná situace (technická platební neschopnost), zatímco trvalá platební neschopnost znamená, že závazky převyšují hodnotu majetku společnosti. Konkurs je soudní řízení o vyrovnání dluhů vůči věřitelům zpeněžením majetku dlužníka a rozdelením takto shromážděných prostředků mezi věřitele. V průběhu konkursu je možné vypracovat plán bankrotu nebo plán restrukturalizace za účelem zachování činnosti dlužníka. Pokud selže restrukturalizační plán, společnost vstupuje do poslední fáze, do fáze likvidace, během které je veškerý majetek společnosti prodán a rozdělen mezi věřiteli a společnost-bankrot právně zaniká (7).

V naprosté většině zdrojů zabývajících se danou problematikou autoři definují bankrot jako neschopnost podniku splácat své závazky, a tím spouští konkurzní procesy (4).

Existuje mnoho definic, které definují úpadek společnosti. Obecně se uznává, že existují dva hlavní důvody úpadku společnosti. Za prvé, k úpadku společnosti může dojít z důvodu jejího opuštění nerentabilní činnosti, i když je skutečně schopná pokrýt své závazky. Insolvence je dalším důvodem, proč firmy končí. Společnosti však v těchto případech nemohou splácat své závazky vůči věřitelům, akcionářům, státu a dalším. Riziko úpadku je jedním z vnitřních rizik podnikání a je způsobeno neplněním včasních plateb (7).

Podle názoru Klieštika (4), který považuje konkurs za formální ukončení existence společnosti z důvodu platné legislativy příslušné země. Podle Dimitrase (4) lze úpadek definovat jako situaci, když společnost není schopná splácat závazky vůči svým věřitelům, vyplácat přednostní akcie akcionářům, platit svým dodavatelům nebo přečerpala své účty nebo společnost zbankrotovala podle příslušného zákona. Autoři Ding

a kol. (4) uvádí, že úpadek je stav, když společnost není schopná spláct své závazky, přednostní dividendy a přečerpala své účty.

1.1.2 Příčiny vzniku bankrotu

Ekonomická krize, která vrcholí v současné době, ukazuje, jak je důležité předvídat riziko bankrotu nejen pro společnosti, ale také pro různé kategorie akcionářů, kteří chtějí chránit svůj investovaný kapitál a využívat výhody poskytovaných příslušným podnikem, jako jsou výplaty dividend. Investoři, kteří chtějí vložit svůj kapitál, také potřebují znát stav podniku předtím, než tak učiní. Věřitelé mají zájem získat zpět kapitál, který přidělili jako úvěr, a obchodní partneři (odběratelé, dodavatelé) chtějí spolupracovat se spolehlivými a bezpečnými podniky, které jsou schopné plnit své smluvní závazky. Tyto faktory ukazují, že předvídání rizika bankrotu je důležité pro úspěch podniku a jeho udržení v konkurenceschopném stavu. Všichni tito subjekty ekonomického života nyní působí v novém kontextu světové ekonomiky, založeném na nových podmírkách rozvoje, nových ekonomických, finančních a sociálních potřebách (8).

Aktuální a závažný problém bankrotů se týká pandemie Covid-19, která měla silný dopad na evropské země, zejména na země střední Evropy. Tento dopad byl patrný v mnoha oblastech ekonomiky, trhu práce a společnosti. Pandemie vedla k nutnému uzavření podniků a snížení poptávky, což vyvolalo velké problémy pro mnoho společností a způsobilo jejich krach (9).

Podle H. Kratochvílové zánik a zrušení firmy může nastat z různých důvodů a různými způsoby jako například (2):

- docílením záměru, jehož mělo být dosaženo;
- dnem stanoveným v rozhodnutí společníků nebo orgánu, dochází-li k zániku firmy fúzí, převodem jmění na společníka nebo v důsledku rozdělení, jinak dnem, ve kterém bylo takové rozhodnutí přijato;
- zrušením konkurzu po splnění rozvrhového usnesení;
- zamítnutím návrhu na prohlášení konkurzu v důsledku nepostačujícího majetku.

V této práci výhradně bude se posuzovat zánik firmy z důvodu nastávání/uznání statusu bankrotu. Podnik nestává bankrotem za jeden den nebo za okamžik. Před bankrotom podnik se nachází po nějakou dobu v krizovém nebo předbankrotném stavu.

Situace, když se podnik stává neschopným spláct své závazky bez ohledu na hodnotu majetku, zaměstnanci nedostávají mzdy v určený výplatní termín a podnik má finanční potíže, charakterizuje krizi předcházející bankrotu podniku (2).

V každé organizaci existuje pravděpodobnost vzniku krize, která může být způsobena nejen chybami ve strategii řízení, nedostatečnou pozorností vývojovým problémům nebo porážkou v konkurenci, ale také tak objektivními faktory, jako jsou výkyvy na trhu, periodická modernizace technologie, změna organizace výroby, změna personálních nebo vnějších ekonomických podmínek a často i politické okolnosti. Bankrot je kritickou variantou krizových jevů v podniku (10).

K rozvoji hospodářské krize a bankrotu podniků může přispět řada faktorů, a to jak externích (úroveň inflace, nestabilita daňové legislativy, finanční a měnové trhy, zvýšená konkurence v průmyslu, nedostatek úvěrových zdrojů atd.), tak vnitřní (úbytek spotřebitelů hotových výrobků, nepravidelná výroba, zvýšení nákladů a snížení produktivity práce, snížení investic do obnovy, modernizace a inovativního výzkumu atd.). Obecně platí, že všechny tyto faktory vytvářejí komplexní souhrn příčinných a následných vztahů (10).

Podle Rukinova je možné vymezit určitý výčet moderních příčin vzniku bankrotu podniků způsoben globálními trendy ve vývoji ekonomiky, ale pro každý důvod existují určité důsledky, které vedou ke zhoršení stavu nebo úpadku a likvidaci (10):

- posílení role nadnárodních společností (TNC), nárůst velkých společností prostřednictvím procesů fúzí a sloučení, a tedy zvýšení úrovně konkurence;
- dynamický rozvoj světové ekonomiky;
- vnitropodnikové skandály;
- růst spotřebitelských požadavků a potřeb na podnikové produkty;
- vzájemná závislost ekonomik různých zemí a možnost dominového efektu během finančních a ekonomických krizí a firemních bankrotů.

Z ekonomického hlediska může podnik v obtížích čelit několika problémům, které mohou ohrozit jeho přežití. Jedním z nich je špatné přizpůsobení prostředí, což může ohrozit podnik. Dalším problémem může být snížení objemu činnosti a ziskovosti, používání nevýkonných technik a nástrojů řízení a obtížná finanční situace. Nízký stupeň využití ve výrobních zařízeních a nezajištění shody: člověk-metoda-stroj jsou také faktory, které

mohou přispět k potížím podniku (11). V závislosti na stupni obtížnosti, ve které se společnost v daném okamžiku nachází, se může dostat do dočasné platební neschopnosti. Délkovající platební neschopnost může vést k bankrotu podniku a jeho následné likvidaci (8).

Potíže, se kterými se společnost setkává, mají různé příčiny. Většina těchto obtíží pochází z konkurenčního a ekonomicko-sociálního prostředí, ve kterém se společnost působí, a mohou být následující (8):

- zvýšení vnitřní a mezinárodní konkurence;
- vznik substitučních produktů;
- úpadek významného dodavatele, který dříve zajišťoval určité materiály, kusy, díly nezbytné pro pokračování činnosti;
- ztráta důležitého klienta nebo jeho úpadek;
- úpadek banky, se kterou měl podnik dominantní finanční vztahy;
- vznik některých předpisů na linii bezpečnosti a ochrany životního prostředí podle nových evropských předpisů;
- neustálý pokles směnného kurzu.

Anghel v roce 2002 se domníval, že faktory, které ovlivňují „zdraví“ společnosti, lze seskupit do tří hlavních složek (8):

- kvalita jednotlivých vlastníků a/nebo managementu;
- charakteristika odvětví;
- ekonomické prostředí, ve kterém působí.

Bailesteau (1998) na základě předchozích studií provedených Altmanem, Argentim a Conanem a Holderem se domnívá, že vznik bankrotu určují následující faktory (8):

- nemožnost splátet současné závazky;
- nedostatek finančních zdrojů na splácení úvěrů;
- inkaso s velkým zpožděním pohledávek;
- rekordní ztráty.

Negativní vývoj těchto faktorů může vést k finanční nerovnováze nebo snížení ziskovosti podnikání, tedy nízké efektivitě až neefektivnosti investic. Tyto situace, pokud se nevyřeší mohou vést k likvidaci (8).

Úpadek může být způsoben úmyslně nebo z hrubé nedbalosti. Způsoby, kterými tato situace může nastat vymezuje Trestní zákoník § 224 odst. 1 a) až e) (12):

- a) činí vydání hrubě nepřiměřená svým majetkovým poměrům,
- b) spravuje svůj majetek způsobem, který neodpovídá zákonem mu uloženým nebo smluvně převzatým povinnostem nebo je s nimi v hrubém nepoměru,
- c) užívá poskytnutý úvěr v rozporu nebo hrubém nepoměru s jeho účelem,
- d) poskytuje ze svého majetku půjčky nebo úvěry jiným osobám, ač to je v hrubém nepoměru k jeho majetkovým poměrům, nebo
- e) učiní nad rámec obvyklého podnikatelského rizika obchod nebo operaci, která nenáleží k jeho pravidelné podnikatelské činnosti nebo je v hrubém nepoměru k jeho majetkovým poměrům,

Pro spáchaní trestního činu stačí kterýkoliv z výše uvedených způsobů.

Dopad bankrotu malých a středních firem se rozšiřuje na širokou škálu zainteresovaných stran, včetně vlastníka, rodiny, přátel, dodavatelů a zákazníků. Pokud selže několik firem, tak ovlivní další společnosti, se kterými měly obchodní vztahy. Příkladem může být to, že bankrotní firmy již nejsou schopné uhradit své závazky vůči jejich obchodním partnerům a tím ovlivní jejich platební schopnost zvýšením počtu neuhraněných pohledávek. Rozsah a dopad bankrotu naznačuje, že pochopení základních příčin je důležité a může poskytnout informace užitečné pro zvýšení pravděpodobnosti přežití malých firem (13).

Analýza autorů Richarda Cartera a Howarda Van Aukena potvrzuje tři jejich hypotézy o tom, co vede k bankrotu, a to (14):

- Firmy s méně zkušenými vlastníky/manažery mají větší pravděpodobnost úpadku než jiné firmy.
- Firmy s horším přístupem ke kapitálu jsou náchylnější k bankrotu než jiné firmy.
- Firmy, které čelí napjatým nebo zhoršujícím se trhům, mají větší pravděpodobnost selhání než jiné firmy.

Uvědomění si důležitosti těchto problémů, snad jako indikátorů blížícího se krachu firmy, může majitelům umožnit vyvinout plány, které lze použít k prevenci finanční tísni a bankrotů (14).

1.1.3 Právní regulace

V českém právním řádu se používají pojmy úpadek a konkurs místo bankrot.

Insolvenční zákon upravuje (3):

„a) řešení úpadku a hrozícího úpadku dlužníka soudním řízením některým ze stanovených způsobů tak, aby došlo k uspořádání majetkových vztahů k osobám dotčeným dlužníkovým úpadkem nebo hrozícím úpadkem a k co nejvyššímu a zásadně poměrnému uspokojení dlužníkových věřitelů,

b) oddlužení dlužníka.“

Z toho vyplývá, že zákon vymezuje několik typu bankrotu podniku jako je úpadek, hrozící úpadek, platební neschopnost a předlužení.

Podle insolvenčního zákona úpadek (resp. bankrot) znamená stav podniku, když má více věřitelů, peněžité závazky po dobu delší 30 dnů po lhůtě splatnosti a tyto závazky není schopen plnit (3).

To znamená, že podnik má více než dva různých subjekty, kterým dlouhodobě dluží, přičemž své závazky vůči těmto subjektům není schopen splnit.

Platební neschopnost (insolvence) nastává, jestli podnik má závazek po dobu delší 30 dnů po lhůtě splatnosti a není schopen své dluhy splnit kvůli tomu, že zastavil platby podstatné části svých peněžitých závazků, nebo je neplní po dobu delší 3 měsíců po lhůtě splatnosti, nebo není možné dosáhnout uspokojení některé ze splatných peněžitých pohledávek vůči dlužníku výkonem rozhodnutí nebo exekucí, nebo nesplnil povinnost předložit seznamy uvedené v zákonu č. 182/2006 Sb. § 104 odst. 1, kterou mu uložil insolvenční soud (3).

Pokud podnik splní aspoň jednu podmínsku z výše uvedených lze ho považovat za platebně neschopného.

Hrozící úpadek – je situace blízka k úpadku a lze důvodně předpokládat, že dlužník nebude schopen rádně a včas splnit podstatnou část svých peněžitých závazků (3).

O předlužení se jedná, když má dlužník více věřitelů a výše jeho závazků převyšuje hodnotu jeho majetku. Při stanovení hodnoty majetku dlužníka se přihlíží i k dalšímu hospodaření s jeho majetkem, popřípadě k dalšímu provozu jeho podniku, lze-li za všech okolností důvodně očekávat, že dlužník bude schopen nadále hospodařit majetek nebo podnikat (3).

Konkurz je soudní řízení, které následuje po úpadku a má za úkol uspokojit věřitele z majetku dlužníka (3).

Rozlišovat tyto pojmy je důležité pro posuzování o skutečné situaci, kterou má podnik a o jeho budoucnosti, jestli může „přežít“ nebo bude zanikat.

Zákon č. 182/2006 Sb., o úpadku a způsobech jeho řešení (insolvenční zákon) upravuje postupy a pravidla pro řešení úpadku a insolvence fyzických a právnických osob. Zákon definuje pojmy jako úpadek, insolvence, konkurs, oddlužení a restrukturalizaci a stanovuje postupy a lhůty pro vedení soudního řízení v těchto záležitostech (3).

Podle zákona může být insolvenční postižen každý, kdo není schopen spláct své dluhy včas a v plné výši. Insolvenční řízení začíná návrhem věřitele, ale může být podán také dlužníkem sám. Cílem insolvence je zajistit, aby byly dluhy věřitelů uhrazeny co nejfektivněji a aby byla ochráněna majetková základna dlužníka (3).

Zákon stanoví také postupy pro řešení úpadku a insolvence, jako jsou oddlužení, restrukturalizace a konkurs. Oddlužení umožňuje dlužníkovi snížit své dluhy a zachovat tak svou podnikatelskou činnost. Restrukturalizace je proces, při kterém se dlužník a jeho věřitelé snaží najít způsob, jak udržet podnikání a dosáhnout dohody o splácení dluhů. Konkurs pak znamená prodej majetku dlužníka za účelem uspokojení věřitelů (3).

Zákon č. 40/2009 Sb. v §224 trestního zákoníku se týká trestného činu způsobení úpadku. Podle tohoto paragrafu se dopustí trestného činu ten, kdo úmyslně způsobí úpadek jinému (12).

Zákon č. 563/1991 Sb., o účetnictví, definuje právní základ pro oceňování majetku a závazků, upravuje zvláštní povinnosti účetních jednotek v případě, že jsou v insolvenci nebo v konkursu. Cílem tohoto zákona je zajištění správné a přesné evidence účetních událostí a majetku v případech, když hrozí bankrot (15).

Zákon č. 89/2012 Sb., občanský zákoník, stanoví povinnost vést spolehlivé záznamy, upravuje zakladatelské právní jednání, jednání za právnickou osobu, definuje pojmy jako je podnikatel, majetek a jmění osob, určuje vznik závazků a jejich obsah (16).

Zákon č. 90/2012 Sb., o obchodních společnostech a družstvech (zákon o obchodních korporacích), vymezuje pravidla jednání členů volených orgánů, vydání prospěchu a ručení člena orgánu při úpadku obchodní korporace, svolání valné hromady s. r. o. kvůli hrozícímu úpadku, jednání jednatelů společnosti s ručením omezeným, svolání valné hromady a. s. kvůli vysoké neuhraněné celkové ztrátě, jednání představenstva (statutárního ředitele) akciové společnosti (17).

Vyhláška č. 190/2017 Sb. upravuje podrobnější pravidla týkající se vyhlášení úpadku, insolvenčního řízení a dalších souvisejících záležitostí podle § 3 odst. 3 insolvenčního zákona. Konkrétně se týká následujících oblastí (18):

- Podmínky pro vyhlášení úpadku
- Způsob a lhůty pro podání návrhu na vyhlášení úpadku
- Postup soudního rozhodování o vyhlášení úpadku a jmenování insolvenčního správce
- Práva a povinnosti insolvenčního správce a dlužníka v insolvenčním řízení
- Způsob a lhůty pro podání pohledávek v insolvenčním řízení
- Způsob a lhůty pro podání návrhu na schválení insolvenčního plánu
- Postup soudního rozhodování o schválení insolvenčního plánu
- Postup při nesplnění insolvenčního plánu a návrhu na ukončení insolvenčního řízení

Vyhláška č. 190/2017 Sb. tak slouží jako praktický nástroj pro aplikaci insolvenčního zákona v praxi (18).

1.2 Malé a střední podniky

1.2.1 Vymezení

Malé a střední podniky (SME) jsou podniky, které udržují tržby, majetek nebo počet zaměstnanců pod určitou hranicí. Každá země má svou vlastní definici toho, co představuje malý a střední podnik. Musí být splněna určitá kritéria velikosti a příležitostně je zohledněno i odvětví, ve kterém společnost působí (19).

Malé a střední podniky (SME) jsou definovány v doporučení EU 2003/361. Za podnik se považuje každý subjekt provozující hospodářskou činnost bez ohledu na jeho právní formu. Patří sem zejména osoby samostatně výdělečně činné a rodinné podniky provozující řemeslnou nebo jinou činnost a partnerství nebo sdružení pravidelně vykonávající hospodářskou činnost. SME je definováno podle stanovených Evropskou Komisi kritérií (20).

1.2.2 Kritéria

Kategorie mikropodniků, malých a středních podniků (SME) je tvořena podniky, které zaměstnávají méně než 250 osob a jejichž roční obrat nepřesahuje 50 milionů EUR a/nebo roční rozvaha nepřesahuje EUR. 43 milionů (20).

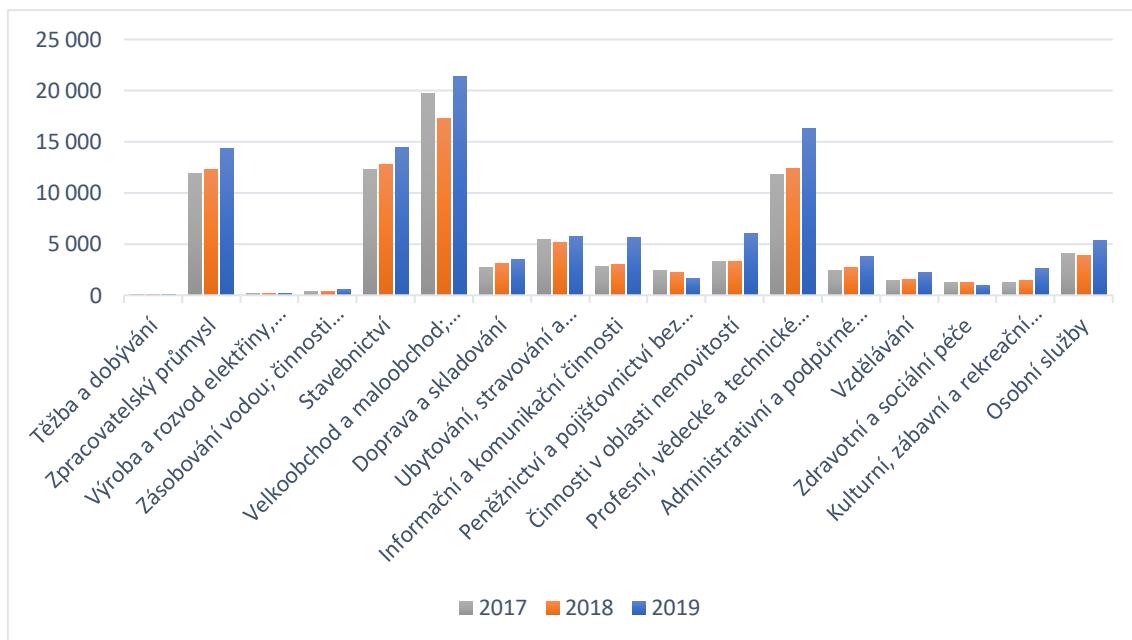
V rámci kategorie SME je malý podnik definován jako podnik, který zaměstnává méně než 50 osob a jehož roční obrat a/nebo roční bilanční suma nepřesahuje 10 milionů EUR (20).

V rámci kategorie SME je mikropodnik definován jako podnik, který zaměstnává méně než 10 osob a jehož roční obrat a/nebo roční bilanční suma nepřesahuje 2 miliony EUR (20).

1.2.3 Význam

Malé a střední podniky představují základní pilíř stabilní tržní ekonomiky a mohou sloužit jako indikátor úspěšnosti ekonomických a daňových opatření zaváděných vládou. Bohužel, tyto podniky se často potýkají s nedostatkem kapitálu a omezeným přístupem k financování, jako jsou bankovní úvěry nebo dotace. Nicméně jsou mnohem lépe přizpůsobivé změnám než velké podniky, přestože jsou vystaveny většímu riziku. V České republice se zvyšuje počet krachujících malých a středních podniků v důsledku finanční krize a jejích následků (21).

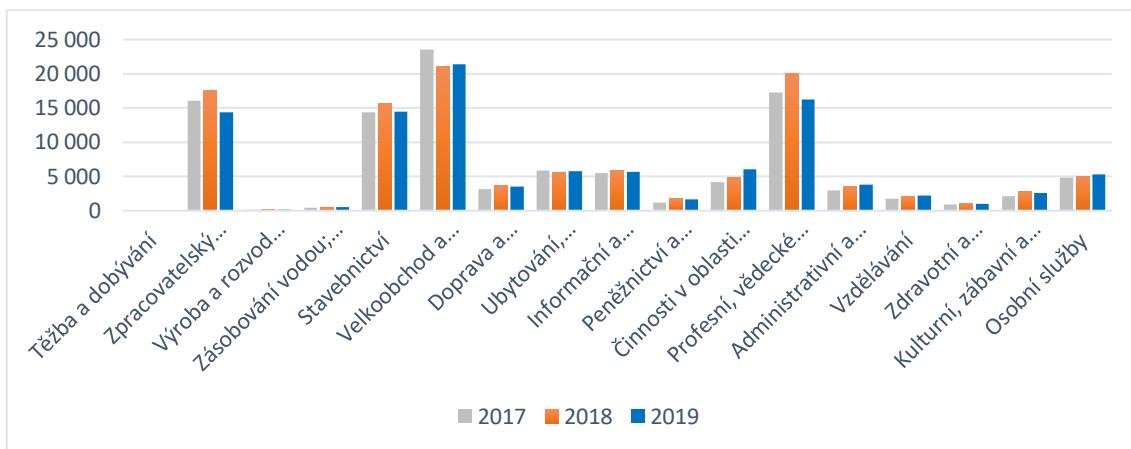
Z grafu č. 1 vyplývá, že počet zaniklých podniků v České republice se liší v závislosti na oblasti ekonomické činnosti. V období 2017 až 2019 byl nejvíce postižen velkoobchod a maloobchod, zpracovatelský průmysl a stavebnictví, kde došlo k výraznému nárůstu počtu zaniklých podniků. Naopak nejméně postižené byly činnosti v oblasti nemovitostí, kde byl zaznamenán stabilní počet zaniklých podniků v celém uvedeném období (22).



Graf č. 1: Počet zaniklých podniků za rok 2017-2019 dle ekonomické činnosti
(Vlastní zpracování dle dat z ČSÚ)

Tabulka č. 1 Počet zaniklých podniků za rok 2017-2019 dle ekonomické činnosti
(Vlastní zpracování dle dat z ČSÚ)

Rok	2017	2018	2019
Těžba a dobývání	13	25	26
Zpracovatelský průmysl	11900	12266	14 338
Výroba a rozvod elektřiny, plynu, tepla a klimatizovaného vzduchu	203	222	179
Zásobování vodou; činnosti související s odpadními vodami, odpady a sanacemi	401	401	560
Stavebnictví	12340	12828	14 481
Velkoobchod a maloobchod; opravy a údržba motorových vozidel	19698	17297	21 347
Doprava a skladování	2736	3073	3 481
Ubytování, stravování a pohostinství	5487	5185	5 792
Informační a komunikační činnosti	2821	3057	5 652
Peněžnictví a pojišťovnictví bez činností holdingových společností	2390	2217	1 680
Činnosti v oblasti nemovitostí	3309	3264	6 067
Profesní, vědecké a technické činnosti	11756	12354	16 272
Administrativní a podpůrné činnosti	2463	2720	3 782
Vzdělávání	1483	1557	2 231
Zdravotní a sociální péče	1295	1223	1 005
Kulturní, zábavní a rekreační činnosti	1241	1429	2 583
Osobní služby	4129	3908	5 330



Graf č. 2: Počet vzniklých podniků za rok 2017-2019 dle ekonomické činnosti

(Vlastní zpracování dle dat z ČSÚ)

Tabulka č. 2: Počet vzniklých podniků za rok 2017-2019 dle ekonomické činnosti

(Vlastní zpracování dle dat z ČSÚ)

Rok	2019	2018	2017
Těžba a dobývání	26	34	33
Zpracovatelský průmysl	14 338	17 583	16 052
Výroba a rozvod elektřiny, plynu, tepla a klimatizovaného vzduchu	179	226	159
Zásobování vodou; činnosti související s odpadními vodami, odpady a sanacemi	560	443	459
Stavebnictví	14 481	15 714	14 387
Velkoobchod a maloobchod; opravy a údržba motorových vozidel	21 347	20 992	23 528
Doprava a skladování	3 481	3 621	3 188
Ubytování, stravování a pohostinství	5 792	5 632	5 832
Informační a komunikační činnosti	5 652	5 908	5 457
Peněžnictví a pojišťovnictví bez činností holdingových společností	1 680	1 748	1 203
Činnosti v oblasti nemovitostí	6 067	4 898	4 219
Profesní, vědecké a technické činnosti	16 272	19 968	17 250
Administrativní a podpůrné činnosti	3 782	3 512	2 988
Vzdělávání	2 231	2 138	1 789
Zdravotní a sociální péče	1 005	1 112	922
Kulturní, zábavní a rekreační činnosti	2 583	2 741	2 115
Osobní služby	5 330	5 062	4 858

Z grafu č. 2 je patrné, že počet vzniklých podniků se v jednotlivých sektorech v průběhu let mírně měnil. Největší nárůst počtu nově vzniklých podniků byl zaznamenán v odvětví

stavebnictví, zpracovatelském průmyslu, a v odvětví velkoobchodu a maloobchodu s opravami a údržbou motorových vozidel. Naopak v odvětví těžby a dobývání byl zaznamenán pokles v počtu nově vzniklých podniků (22).

Celkově lze říci, že se ekonomika České republiky v průběhu let pomalu rozvíjí a vznikají nové podniky, přičemž v některých sektorech je tento trend více patrný než v jiných. Nicméně, pokud porovnáme oba grafy, je vidět, že počet zaniklých a vzniklých podniků ve zpracovatelském průmyslu a ve stavebnictví se poměrně neliší a je v poměru přibližně 3:4 zaniklých k vzniklým.

1.3 Zpracovatelský průmysl

Zpracovatelský průmysl v České republice podle CZ NACE je označován jako C. Jedná se o kategorii odvětví, která zahrnuje výrobu a zpracování surovin, polotovarů a výrobků v průmyslovém sektoru. Mezi nejvýznamnější odvětví v rámci CZ-NACE C patří potravinářský průmysl, strojírenství, elektrotechnika, chemický průmysl a výroba plastů. Zpracovatelský průmysl je pro českou ekonomiku velmi důležitý a tvoří významnou část HDP (23).

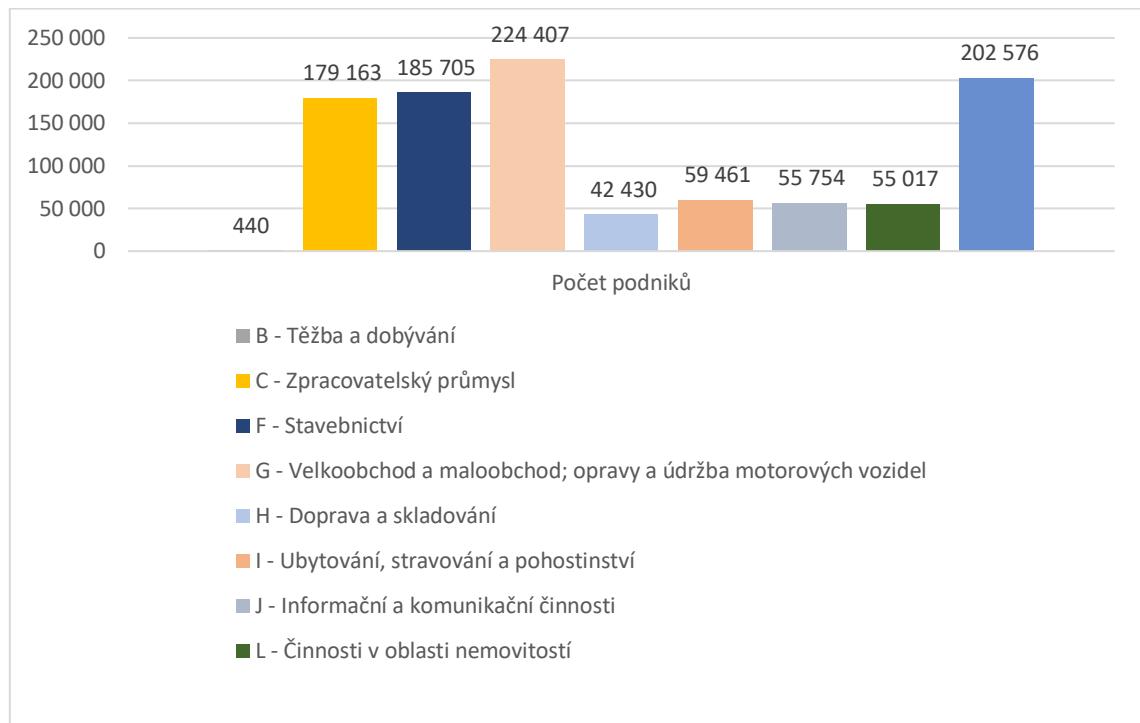
1.3.1 Pojem

Zpracovatelský průmysl bývá definován následovně: „*Tato sekce zahrnuje mechanickou, fyzikální nebo chemickou přeměnu materiálů nebo komponentů na nové produkty (zboží), ačkoliv toto nelze použít jako jednotné univerzální kritérium pro definování výroby zboží, tj. zpracovatelského průmyslu, (dále pod poznámkou ke zpracování odpadů). Materiály, látky a suroviny, které se využívají jako vstupy zpracovatelského průmyslu, jsou produkty zemědělství, lesnictví, rybolovu a akvakultury, těžby, dobývání kamene a písků a jílů nebo se též může jednat o produkty jiných zpracovatelských činností. Podstatná změna, renovace nebo rekonstrukce produktů se obecně považuje za výrobu zboží, a zařazuje se tedy do zpracovatelského průmyslu. Výsledkem výrobního postupu jsou bud' hotové výrobky určené pro užívání nebo spotřebu, nebo polotovary určené k dalšímu opracování nebo zpracování.“* (23).

1.3.2 Podíl na celkovém trhu

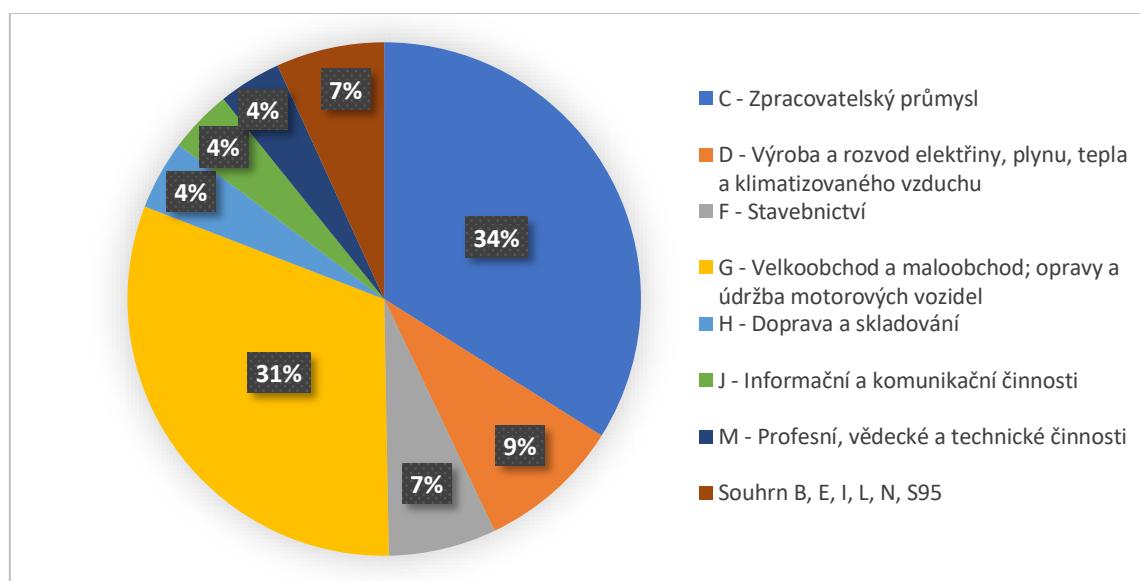
Graf č. 3 zobrazuje počet podniků, které působí v každém konkrétním odvětví dle CZ-NACE v České republice za rok 2020. Největší počet podniků mají velkoobchod

a maloobchod, stavebnictví, profesní, vědecké a technické činnosti a zpracovatelský průmysl (22).



Graf č. 3: Počet podniků za rok 2020 dle ekonomické činnosti

(Vlastní zpracování dle dat z ČSÚ)



Graf č. 4: Podíl odvětví podle CZ-NACE dle obratu (mil. CZK)

(Vlastní zpracování dle dat z ČSÚ)

Graf č. 4 zobrazuje obraty v jednotlivých sektorech ekonomiky České republiky v milionech korun za rok 2020. Nejvyšší podíl podle obratu v roce 2020 měl zpracovatelský průmysl s 34 % na celkové částce, následovaným odvětvím velkoobchodu a maloobchodu s podílem 31 %. Stavebnictví mělo podíl 7 %, zatímco výroba a rozvod elektřiny, plynu, tepla a klimatizovaného vzduchu měla 9 %. Menší podíly měly sektory dopravy a skladování, informační a komunikační činnosti, profesní, vědecké a technické činnosti – 4 % (22).

Vzhledem k tomu, že zpracovatelský průmysl tvoří značnou část ekonomiky a má vliv na mnoho dalších odvětví, bylo rozhodnuto použít data z tohoto odvětví pro testování a vytvoření bankrotního modelu. Navíc, zpracovatelský průmysl je relativně stabilní a má poměrně předvídatelný vývoj, což usnadňuje predikci budoucích trendů. Data z tohoto odvětví jsou k dispozici v dostatečném množství vzorků a s dostatečnou mírou detailu.

1.4 Metody tvorby modelů

V oblasti predikce bankrotu firmy existuje řada různých vědeckých metod a modelů, které se snaží poskytnout informace o budoucích obchodních operacích podnikatelského subjektu a jeho šancích na přežití. Většina autorů těchto metod se zaměřila na analýzu finančních poměrových ukazatelů, což představuje mikroekonomický přístup k predikci bankrotu. Pro odvození modelů, které jsou aplikovatelné na konkrétní podmínky v dané zemi, autoři využili výsledků předchozích výzkumů (7).

Mnoho autorů vytvořilo různé modely, aby předpovědělo riziko bankrotu. Analýza rizika bankrotu se provádí několika metodami, z nichž každá odhaluje jiné aspekty rizika bankrotu. Tyto modely zahrnují jak kvantitativní, tak kvalitativní proměnné. Také máme (8):

- Tradiční metody také nazývané „účetní metody“ založené na finančních (kvantitativních) kritériích – finanční ukazatele: likvidita, zadluženost, ziskovost, peněžní poměr atd.
- Metody založené na nefinančních (kvalitativních) kritériích, jako jsou následující: Metody řízení; Metody konkurenční strategie; Metody založené na přístupu udržitelného rozvoje;
- Jiné metody (na základě kritických připomínek auditorů, na základě makroekonomického růstu, zákona).

- Statistické metody (založené na diskriminační analýze, analýze logit/probit a modelu nebezpečí). Statistické metody jsou založeny většinou na finančních kritériích, ale mohou být upraveny nefinančními kritérii, jako je velikost činnosti, odvětví činnosti, riziko země atd.).

Mnohé z těchto modelů jsou založeny na matematických a statistických metodách (zejména regresní a diskriminační analýza). Modely predikce bankrotu lze rozdělit do tří skupin: statistické modely, modely využívající umělou inteligenci a teoretické modely. Statistické modely lze rozdělit do dvou skupin: jednorozměrné a vícerozměrné. Vícerozměrné statistické modely zahrnují vícerozměrné modely diskriminační analýzy, lineární pravděpodobnost, logitové modely, probitové modely a celkové kumulativní a částečné úpravy (24).

Modely pro predikci bankrotu jsou z velké části založeny na vícerozměrných technikách statistické analýzy, mezi které patří například vícenásobná diskriminační analýza, logitové a probitové analýzy. Tyto statistické metody pomáhají odhalit vztahy mezi jednotlivými finančními ukazateli a pravděpodobností bankrotu firmy. Výsledky analýzy se pak používají k vytvoření prediktivního modelu, který dokáže s určitou přesností predikovat bankrotové riziko podniku. Celkově lze tedy říci, že pro predikci bankrotu firmy se využívají především statistické metody a modely, které kombinují výsledky finanční analýzy s technikami statistické analýzy a predikce (7).

Využití poměrových ukazatelů má tu výhodu, že ve srovnání s absolutními úrovněmi ukazatelů poskytují určitou obecnou použitelnost. Používáním finančních poměrových ukazatelů z velké části se odstraňují limity generované velkými firmami (8).

Studie zdůrazňují důležitost finančních ukazatelů pro predikci rizika bankrotu pomocí statistických metod, odborníci upozorňují na to, že tyto modely nejsou dokonalé a měly by být doplněny o nefinanční přístupy. Ty zahrnují věk podniku, podíl na trhu, forma vlastnictví, odvětví činnosti, kvalitu manažerského týmu, kritické komentáře auditora a další faktory. Doplnění těchto faktorů by mohlo zvýšit přesnost predikce a umožnit lepší identifikaci rizik, které by mohly mít vliv na finanční situaci podniku (8).

Například ve studii Y. WU (25) autoři porovnávali výkonnost několika alternativních modelů predikce bankrotu na vzorku britských firem. Testované modely zahrnují tradiční statistické metody, jako jsou logistická regrese a diskriminační analýza, stejně jako

novější techniky: rozhodovací stromy a umělé neuronové sítě. Výsledky naznačují, že i když žádný model nepřevyšuje přesnost všech ostatních ve všech případech, určité modely jsou vhodnější pro konkrétní typy firem nebo odvětví. Například model rozhodovacího stromu fungoval lepě pro firmy v sektoru služeb, zatímco model logistické regrese byl účinnější pro firmy ve zpracovatelském průmyslu. Autoři dospěli k závěru, že nejlepší výsledky při předpovídání rizika bankrotu pravděpodobně přinese kombinace modelů, spíše než spoléhání se na jedinou metodu. Rovněž poznamenávají, že začlenění kvalitativních informací, jako jsou komentáře vedení a zprávy analytiků, může zlepšit přesnost předpovědí (25).

V této diplomové práci se vyskytují dvě statistické metody: lineární diskriminační analýza a analýza logit (logistická regrese). V této podkapitole bude každá z těchto metod podrobně popsána a vysvětlena.

1.4.1 Lineární diskriminační analýza

Lineární diskriminační analýza je statistická metoda používaná k analýze dat, která se snaží najít lineární kombinaci proměnných, která nejlépe rozlišuje mezi dvěma nebo více skupinami. Tato metoda se často používá pro klasifikaci, například rozlišení mezi dvěma skupinami lidí na základě jejich výšky a hmotnosti, rozlišení mezi zdravými a nemocnými pacienty na základě jejich zdravotních dat, nebo rozlišení mezi spamem a ne-spamem v e-mailových zprávách na základě různých proměnných (26).

Lineární diskriminační analýza hledá lineární kombinaci proměnných, která nejlépe odděluje skupiny. Tento lineární kombinace se nazývá diskriminační funkce. V případě dvou skupin je diskriminační funkce jednoduše lineární rovnice, která rozděluje proměnné na dvě skupiny. Pokud jsou skupiny více než dvě, pak se hledá několik diskriminačních funkcí, každá pro jednu dvojici skupin (26).

Pro výpočet diskriminační funkce se používá tzv. Fischerova diskriminační analýza, která se snaží maximalizovat poměr mezi skupinovou variancí a vnitroskupinovou variancí. Tento poměr zajišťuje, že diskriminační funkce bude oddělovat skupiny co nejlépe (26).

Mezi hlavní výhody lineární diskriminační analýzy patří (26):

- Dobrá schopnost klasifikace dat: analýza může přesně rozdělit data do skupin a určit, do které skupiny data patří na základě jejich vlastností;

- Schopnost pracovat s vícerozměrnými daty: analýza může pracovat s velkým počtem proměnných, což je užitečné při analýze dat s mnoha různými vlastnostmi.
- Interpretace výsledků: analýza umožňuje interpretovat výsledky a pochopit, jak jednotlivé vlastnosti dat přispívají k rozdělení do skupin.

Mezi nevýhody patří (26):

- Předpoklad lineární závislosti: předpokládá lineární závislost mezi proměnnými, což může být problém u dat s ne-lineárními vztahy mezi vlastnostmi.
- Předpoklady: analýza vyžaduje několik předpokladů, jako je normalita dat, nezávislost proměnných.

1.4.2 Konkrétní aplikace metody lineární diskriminační analýzy

Altmanův model bankrotu je založen na vícenásobné diskriminační analýze, kterou Altman poprvé použil v roce 1968. Tento model je vytvořen za účelem určení finanční tísni podniku a predikce jeho bankrotu. Altman použil vlastní databázi společností kótovaných na NYSE, které prosperovaly, i firem, které zbankrotovaly, a zahrnul do modelu pět nejdůležitějších finančních poměrových ukazatelů. Tyto ukazatele jsou váženy a spočítány do diskriminační funkce, která rozděluje podniky na ty, které mají vyšší pravděpodobnost bankrotu a ty, které nezbankrotují. Altman dále popsal metodu diskriminační analýzy a další modely vhodné pro predikci finanční tísni ve svých knihách Financial Ratios, Discriminant Analysis a Corporate Failure Forecasting and Corporate Financial Disaster z roku 2006. Tyto modely a metody jsou využívány v praxi pro analýzu finančního zdraví firem a predikci finančních problémů (8).

V obecném přístupu vícenásobná diskriminační analýza je skórovací metoda založena na statisticky stanoveném počtu bloků (ukazatelů), váženém některými koeficienty v matematickém modelu, který by mohl s určitou pravděpodobností určit budoucí zdraví podniku. Analyzovanému podniku je tedy přiřazena nota Z, nazývaná „ZETA skóre“, která je vypočtena pomocí lineární kombinace několika proměnných. Vícenásobná diskriminační analýza se používá k určení, které z těchto proměnných mají největší vliv na predikci budoucího stavu podniku a jakým způsobem by měly být váženy. Poté je na základě vážených ukazatelů vypočteno ZETA skóre. Toto skóre slouží jako prediktivní ukazatel budoucího stavu podniku, a to buď jako pravděpodobnost bankrotu nebo jako

výkonnostní ukazatel. V závislosti na získané hodnotě skóre je subjekt považován za zdravý nebo v úpadku. Obecné model vypadá následovně (8,27):

$$Z = Z_1X_1 + Z_2X_2 + Z_3X_3 + \dots + Z_nX_n$$

kde:

Z1, Z2, Z3 ... Zn – představuje vážené koeficienty, které určují jejich relativní důležitost v modelu. Celkové Z-skóre pak poskytuje predikci pravděpodobnosti bankrotu společnosti;

X1, X2, X3 – představuje hodnoty diskriminačních finančních poměrů.

Modely vytvořené pomocí vícenásobní diskriminační analýzy mají v hodnocení šedou zónu. Například, Altmanovo Z-skóre má hranice hodnocení (27):

$Z \in < 2,99; \infty)$ – podnik je aktivní;

$Z \in (1,81; 2,99)$ – šedá zóna

$Z \in (-\infty; 1,81)$ - bankrotní podnik

Šedá zóna v bankrotních modelech se obvykle vztahuje na situace, když skóre podniku se pohybuje v blízkosti kritické hranice mezi solventností a nesolventností, což ztěžuje přesné určení, zda je firma ohrožena bankrotom. V takovém případě není možné s jistotou určit, zda firma bude nadále prosperovat nebo se dostane do finanční tísni. V některých modelech se proto používají speciální techniky pro zohlednění této nejistoty a zvýšení spolehlivosti predikce. Například Altmanův Z-skóre pro predikci bankrotu zahrnuje určitou toleranci pro šedou zónu a dává těmto firmám hodnotu, která odráží jejich rizikovou povahu a pravděpodobnost bankrotu (8).

Vícenásobná diskriminační analýza má své výhody a nevýhody (28):

Výhody:

- je uznávaná a ověřená metoda pro hodnocení finanční stability podniků;
- umožňuje identifikovat klíčové faktory, které ovlivňují finanční stabilitu podniků a umožňuje jim přizpůsobit své strategie a řízení k těmto faktorům;
- může být použita pro různé typy podniků a různé obory;
- může být použita pro predikci bankrotů a finanční tísni.

Nevýhody:

- může být ovlivněna chybami v datových zdrojích nebo nepřesnostmi v hodnocení ukazatelů;
- nemusí být vždy spolehlivá v době krize, když jsou podniky vystaveny mnoha vnějším vlivům, které mohou ovlivnit jejich finanční situaci.
- se spoléhá na existující data a může být omezena omezeným množstvím dat, která jsou k dispozici.

1.4.3 Logit analýza

Logit a Probit analýzy jsou statistické metody, které se používají k predikci pravděpodobnosti, že firma zbankrotuje. Tyto metody se začaly používat v 70. letech, ale jejich popularita byla nižší než u metody vícenásobné diskriminační analýzy, která se používala od konce 60. let. Vícenásobná diskriminační analýza používá skóre vypočítané z různých faktorů k určení pravděpodobnosti bankrotu, zatímco Logit a Probit analýzy používají vektor vysvětlujících proměnných pro predikci pravděpodobnosti bankrotu. Tyto metody využívají statistické modelování a výpočty, aby poskytly kvantitativní predikce pravděpodobnosti bankrotu na základě konkrétních proměnných (8).

Výhodou logistické regrese oproti diskriminační analýze je vyšší prediktivní schopnost a nepotřebuje dodržení předpokladů, které by mohly omezit její použitelnost (např. normalita dat, lineární vztah mezi proměnnými, nezávislost dat) (24).

Logit model umožňuje modelovat komplexní vztahy mezi proměnnými, ale zároveň předpokládá logaritmicko-lineární vztah mezi proměnnými odezvy (závislé) a vysvětlujícími proměnnými (nezávislé). Je vhodný zejména pro předpovídání binárních výstupů, tedy klasifikace do jedné ze dvou kategorií na základě hodnoty jedné nebo více nezávislých proměnných. V případě tvorby bankrotního modelu je tedy výstupem binární proměnná, která udává, zda daná společnost zbankrotovala (1) nebo nezbankrotovala (0). Je důležité poznamenat, že pro malá data může být užitečnější diskriminační analýza, zatímco pro větší vzorky se doporučuje logistická regrese. Nicméně, logit modely mají své slabiny, jako například citlivost na vzdálená pozorování. To znamená, že jednotlivá pozorování, která jsou výrazně odlišná od ostatních, mohou významně ovlivnit výsledky modelu. Tyto odlehlé hodnoty mohou být způsobeny například chybou v datech. Pro zlepšení výsledků je tedy důležité věnovat pozornost identifikaci a odstranění odlehlých hodnot (24).

Pomocí logistické transformace jsme specifikovali pravděpodobnost P_i pomocí následujícího modelu (8):

$$P_i = f(\alpha + \beta x_i),$$

kde

x_i představuje vybrané finanční ukazatele a α a β jsou odhadované parametry.

P_i se pak vypočítá pomocí následující logistické funkce (8):

$$P_i = \frac{\exp(\alpha + \beta x_i)}{1 + \exp(\alpha + \beta x_i)} = \frac{1}{1 + \exp(-\alpha - \beta x_i)}$$

Podle (8) lze logitový model zapsat následovně:

$$\text{logit} = \ln\left(\frac{P_i}{1-P_i}\right) = f(\alpha + \beta x_i),$$

Výše uvedený vzorec představuje přirozený logaritmus poměru šancí dvou možných alternativ (P_1, P_0). Cílem logistické regrese je vypočítat poměr šancí ($\frac{P_i}{1-P_i}$); v tomto vztahu přirozený logaritmus představuje logitovou transformaci (8).

Na základě výsledků logit modelu, kde byly použity vysvětlující proměnné (např. likvidita, zadluženost, rentabilita atd.), můžeme určit pravděpodobnost bankrotu podniku. Pro tento účel můžeme použít cut-off skóre, obvykle nastavené na úrovni 0,5, a podniky nad touto hodnotou jsou považovány za ohrožené bankrotem, zatímco podniky pod touto hodnotou mají nižší (nebo žádnou) pravděpodobnost bankrotu. Chyba typu I (false negative rate) vzniká, když bankrotní podnik je chybně klasifikován jako nebankrotní/aktivní a nedostává tak potřebnou pomoc. Naopak, chyba typu II (false positive rate) vzniká, když je společnost, která není bankrotem, chybně klasifikována jako ohrožená bankrotem a dostává tak nadbytečnou pomoc, což může být nežádoucí z hlediska efektivnosti využití zdrojů. Tyto chyby lze minimalizovat nastavením optimálního cut-off skóre, které bude záviset na specifických podmínkách a cílech analýzy (8).

Mezi výhody logistické regrese patří jednoduchá použitelnost, snadná interpretace výsledků a vysoká přesnost, kterou zajišťuje metoda maximální věrohodnosti. Další výhodou je schopnost zahrnout do modelu charakteristiky, které nejsou silnými

prediktory, ale jsou podstatné z obchodních nebo ekonomických důvodů. Logistická regrese je také běžně dostupná v mnoha statistických softwarových nástrojích (29).

Nevýhodou logistické regrese je potřeba detailní přípravy dat. Je nutné provést úpravu databáze, aby byla odstraněna multikolinearita, logické chyby při sběru dat a úprava neúplných dat, což může být překážkou při tvorbě modelu logistické regrese. Další nevýhodou je omezení použití pouze na binární výstupy a neschopnost modelovat složitější vztahy mezi vysvětlujícími a vysvětlovanými proměnnými (29).

1.4.4 Omezení modelů predikce bankrotu

V článku Grice a Dugana popisují o omezeních modelů predikce bankrotu a nabízí některá varování pro výzkumníky pracující v této oblasti. Autoři tvrdí, že zatímco modely predikce bankrotu mohou být užitečnými nástroji pro hodnocení úvěrového rizika, existuje několik omezení, kterých by si výzkumníci měli být vědomi (30).

Jedním z klíčových omezení modelů predikce bankrotu je, že jsou založeny na historických datech, a ne vždy můžou být schopny přesně předvídat budoucí bankroty. Je to proto, že ekonomické a tržní podmínky, které vedly k bankrotům v minulosti, nemusí být stejné jako ty, které nastanou v budoucnu. Modely predikce bankrotu navíc nemusí brát v úvahu určité kvalitativní faktory, které mohou ovlivnit bonitu společnosti, jako jsou změny ve vedení nebo zvýšení konkurence (30).

Dalším omezením modelů predikce bankrotu je to, že mohou podléhat nadměrnému dovybavení. K dovybavení dochází, když je model trénován na malém vzorku dat a poté aplikován na větší vzorek, což vede k nepřesným předpovědím. To může být problém, pokud je model predikce bankrotu založen na malém počtu bankrotů, protože nemusí být schopen přesně předpovědět bankroty na větším vzorku (30).

Autoři rovněž varují, že spoléhání se pouze na bankrotní predikční modely při rozhodování je nedostačující. Je třeba provést komplexní analýzu podniku a na základění usuzovat, nikoli se spoléhat pouze na jeden model. Modely predikce bankrotu mohou být užitečným nástrojem, avšak měly by být používány ve spojení s dalšími zdroji informací, jako jsou finanční výkazy a rozhovory s vedením, aby byl získán úplný obraz o bonitě společnosti (30).

1.5 Hodnocení proměnných

1.5.1 Korelace

Multikolinearita se vyskytuje, když v modelu existuje vysoká lineární závislost mezi vysvětlujícími proměnnými. Jednou z metod, jak ji můžeme vypočítat, je koeficient párové korelace, který určuje míru korelace mezi dvěma proměnnými. Pokud je hodnota koeficientu vyšší než 0,75, jedná se o silné párové korelati mezi proměnnými a může znamenat, že jsou tyto proměnné multikolineární. Pokud je korelační koeficient blízký -1, znamená to, že existuje silná negativní korelace mezi dvěma proměnnými, což znamená, že když se jedna proměnná zvyšuje, druhá klesá a naopak. Pokud je korelační koeficient blízký +1, znamená to, že existuje silná pozitivní korelace mezi dvěma proměnnými, což znamená, že když se jedna proměnná zvyšuje, zvyšuje se i druhá. Pokud je korelační koeficient blízký 0, znamená to, že mezi proměnnými neexistuje žádná lineární závislost (29).

Vysoká míra multikolinearity může vést k neschopnosti odhadnout vliv každé z proměnných na závislou proměnnou. To může vést k neplatnosti regresního modelu a nemožnosti provést výpočty. Kromě toho může multikolinearita vést k nejistotě ohledně příčinných vztahů mezi proměnnými a ke špatné interpretaci výsledků regresní analýzy (29).

Jednou z možností řešení multikolinearity je odstranění nebo transformace proměnných, které způsobují vysokou závislost. Pokud je multikolinearita stále přítomna, může být nutné získat nový vzorek dat nebo provést výběr nových vysvětlujících proměnných (29).

Je důležité provést analýzu multikolinearity před použitím regresní analýzy a případně ji řešit, aby bylo zajištěno správné a spolehlivé využití regresního modelu.

1.5.2 T-test

Pro účely diplomové práce v praktické části byl použit t-test pro porovnání průměru dvou nezávislých souborů dat a testování hypotézy o jejich shodě.

Levenův test, pojmenovaný podle amerického statistika Hermana O. Levene, slouží k testování shody rozptylů mezi dvěma nebo více skupinami dat. Testování shody rozptylů je důležité, protože pokud jsou rozptyly mezi skupinami různé, může to vést k nesprávnému vyhodnocení vztahů mezi proměnnými a k chybným závěrům. Levenův

test se snaží detektovat signifikantní rozdíly mezi rozptyly jednotlivých skupin a umožňuje tak určit, zda jsou rozdíly mezi skupinami skutečné, nebo zda jsou způsobeny pouze náhodou. Výsledkem testu je F-test a příslušná p-hodnota. Pokud je výsledná p-hodnota Leveneova testu nižší než stanovená hladina významnosti (obvykle 0,05), znamená to, že rozdíly v rozptylech mezi vzorky by pravděpodobně nevznikly pouze náhodně, ale jsou statisticky významné. To vede k zamítnutí nulové hypotézy o shodě rozptylů mezi vzorky a naznačuje existenci rozdílu mezi rozptylem v jedné nebo více populacích (31).

Studentův t-test porovnává průměr číselné datové řady s předem určenou konstantou, která je na datech výběru nezávislá a určení, zda jsou tyto průměry statisticky významně odlišné. Nulovou hypotézou je tvrzení, že střední hodnota se rovná konstantě, přitom se předpokládá, že data pocházejí z normálního rozložení a shodnosti rozptylů obou souborů. Existují dva typy t-testů pro porovnání průměrů: nezávislý t-test a závislý t-test. Při porovnání průměrů dvou souborů hodnot je důležité určit, zda jsou rozptyly těchto souborů homogenní. Pokud nejsou, je nutné použít modifikovanou verzi t-testu, tzv. Welchův t-test, který bere v úvahu různé rozptyly obou souborů. V praktické části byl použit nezávislý t-test (32).

Welchův t-test slouží k testování statistické významnosti rozdílu mezi průměry dvou nezávislých vzorků, když nelze předpokládat, že mají stejný rozptyl. Tento test se používá v situacích, když je rozptyl jedné nebo obou vzorků různý a není možné použít tradiční Studentův t-test, který předpokládá stejný rozptyl pro oba vzorky (31).

Welchův t-test vychází z předpokladu, že oba vzorky mají normální rozdělení a jsou nezávislé. Testuje nulovou hypotézu, že rozdíl mezi průměry dvou vzorků je roven nule, a alternativní hypotézu, že rozdíl mezi průměry dvou vzorků není roven nule (31).

Výsledkem testu je t-hodnota a p-hodnota. Pokud je p-hodnota menší než zvolená hladina významnosti, obvykle 0,05, znamená to, že existuje statisticky významný rozdíl mezi průměry dvou vzorků (31).

1.6 Hodnocení výkonnosti modelu

1.6.1 ROC křivka

ROC (Receiver Operating Characteristic) grafy jsou užitečným nástrojem pro vizualizaci výkonu klasifikátorů a často se používají pro hodnocení výkonnosti modelu logistické regrese. ROC analýza umožňuje hodnotit citlivost a specifičnost testů a tím posuzovat jejich hodnotu. ROC křivka se obvykle získává tím, že se postupně zvyšuje prahová hodnota klasifikátoru a počítají se příslušné hodnoty pro četnost falešných pozitivních a skutečně pozitivních výsledků. Pro sestavení grafu se používá matice zvaná "matice záměn", která se používá pro výpočet hodnot metrik, jako je například přesnost (accuracy), přesnost predikce pozitivní třídy (precision), úplnost predikce pozitivní třídy (recall) atd. Matice záměn je čtyřbodová tabulka, která zobrazuje počty správných a nesprávných klasifikací pozitivní a negativní třídy, na základě výstupů klasifikátoru a skutečných tříd. Matice záměn tedy poskytuje detailní informace o výkonnosti klasifikátoru a lze ji použít k výpočtu metrik výkonnosti, které jsou důležité pro hodnocení klasifikačních algoritmů. Na obrázku č. 1 je zobrazena matice (33).

		Actual	
		Positive	Negative
Predicted	Positive	TP	FP
		True positive	False Positive
Predicted	Negative	FN	TN
		False Negative	True Negative

Obrázek č. 1: Matrice záměn

Zdroj: vlastní zpracování dle (33)

Falešné pozitivní míra se počítá (33):

$$\text{False positive rate (FPR)} = \frac{FP}{FP + TN}$$

Falešné negativní míra se počítá (33):

$$\text{False negative rate (FNR)} = \frac{FN}{FN + TP}$$

Senzitivita (také známá jako True Positive Rate nebo Recall) je míra, která udává, jak dobře klasifikátor identifikuje pozitivní případy (33):

$$Sensitivity = \frac{TP}{TP + FN}$$

Specifita je míra používaná k vyhodnocení výkonu klasifikátoru a vztahuje se k jeho schopnosti správně identifikovat negativní případy (33):

$$Specificity = \frac{TN}{TN + FP}$$

Youdenův index je míra používaná pro hodnocení výkonu klasifikačního modelu. Matematicky se to dá vyjádřit jako (33):

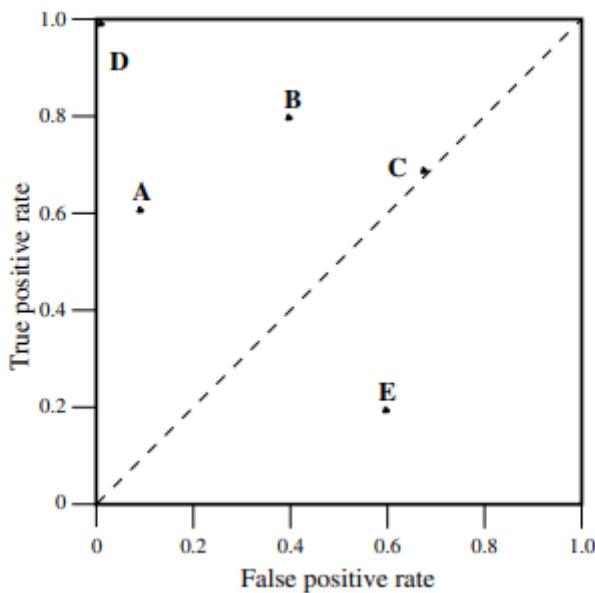
$$Youden\ index = Sensitivity + Specificity - 1$$

Youdenův index nabývá hodnot od -1 do 1, kde hodnota 1 znamená, že klasifikační model má 100 % senzitivitu a 100 % specifitu a hodnota -1 znamená, že klasifikační model má 0 % senzitivitu a 0 % specifitu. Optimální hodnota indexu pro klasifikační model je 1, což znamená, že model má dokonalou schopnost rozlišovat mezi pozitivními a negativními případy (33).

Přesnost (accuracy) je míra pro vyhodnocení klasifikátoru, která udává podíl správně klasifikovaných případů k celkovému počtu případů. Tuto metriku lze vypočítat pomocí následujícího vzorce (33):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

ROC grafy jsou dvourozměrné grafy, ve kterých je míra skutečné pozitivních případů vynesena na ose Y a míra falešné pozitivních případů je vynesena na ose X. ROC graf zobrazuje relativní kompromisy mezi skutečně pozitivní a falešné pozitivní. Obrázek č. 2 ukazuje graf ROC s pěti klasifikátory označenými A až E (33).



Obrázek č. 2: Základní ROC graf

(Zdroj: 33)

Každý bod na ROC grafu představuje jinou kombinaci sensitivity a specificity klasifikátoru při dané prahové hodnotě. Tyto body jsou vytvořeny tím, že se postupně mění prahová hodnota pro klasifikaci pozitivní a negativní třídy, a pro každou prahovou hodnotu se vypočítají hodnoty sensitivity a specificity. Bod D představuje skoro dokonalé zařazení. Dokonalým bodem je (0;1). Klasifikátory objevující se na levé straně grafu ROC poblíž osy X lze považovat za „konzervativní“: vytvářejí pozitivní klasifikace pouze se silnými důkazy, takže dělají málo falešně pozitivních chyb. Klasifikátory v pravé horní části grafu ROC lze považovat za „liberální“: vytvářejí pozitivní klasifikace se slabými důkazy, takže klasifikují téměř všechny pozitivní správně, ale často mají vysokou míru falešně pozitivních výsledků. Například bod A je konzervativnější než B. Výsledkem jsou body na grafu, které mohou být propojeny křivkou. Čím větší je plocha pod křivkou (AUC), tím lepší je výkon klasifikátoru (33).

1.6.2 Plocha pod křivkou AUC

Plocha pod křivkou AUC (Area Under Curve) je plocha ve formě tabulky, která se používá k vyhodnocení diskriminační schopnosti klasifikátorů pomocí ROC křivek. AUC nabývá hodnot mezi 0,5 a 1. Hodnota 0,5 znamená, že klasifikátor nemá žádnou

diskriminační schopnost a jeho výsledky jsou náhodné. Hodnota 1 znamená, že klasifikátor je dokonalý a všechny případy jsou klasifikovány správně. ROC křivka je nezávislá na předpokládané prevalenci jednotlivých tříd v populaci, což je výhoda této plochy (34).

1.7 Bankrotní modely

Diagnostika finančního zdraví firmy a predikce jejího neúspěchu jsou v současnosti velmi diskutovanými tématy. Pro udržení prosperity a konkurenceschopnosti je nesmírně důležité, aby společnost znala svou finanční situaci. Bez detailních analýz finančního zdraví nelze dělat adekvátní manažerská rozhodnutí. Kvalitní, komplexní a včasná diagnostika podpořená podrobnou analýzou nepříznivých jevů je důležitým předpokladem efektivního rozhodování majitelů firem. Na základě těchto výsledků může management společnosti přijímat účinná opatření ke zlepšení finanční situace. Výsledky analýz jsou velmi důležité nejen pro majitele a manažery firem, ale také pro investory a banky, protože do značné míry určují všechna jejich rozhodnutí ve vztahu k podnikům (24).

Finanční riziko zahrnuje možnost ztráty investice v případě, že společnost nesplní své finanční závazky kvůli nedostatečným peněžním tokům. Společnost může využívat dluhové financování, což znamená, že věřitelé mají přednostní nárok na splacení svých dluhů před akcionáři. Pokud společnost nemůže splatit své dluhy, hrozí jí platební neschopnost. Predikční modely jsou využívány k hodnocení finančního zdraví společností a mohou pomoci včas identifikovat hrozící problémy a minimalizovat finanční riziko pro investory. Tyto modely využívají finanční ukazatele a jiné charakteristiky společností a jejich okolí k posouzení finančního zdraví a predikci budoucího vývoje (35).

První model pro předpovídání bankrotu a finanční tísni byl vyvinut ve Spojených státech, s cílem vytvořit systém včasného varování a identifikovat důvody finančních problémů. Původně se předvídání finančních potíží zaměřovalo především na střední a velké společnosti, neboť jejich finanční zprávy byly snadněji dostupné. Nicméně Robert O. Edminster patřil mezi první, kteří se začali zabývat predikcí finančních potíží u malých společností. Sestavil vzorek 562 malých firem a použil 19 nejčastěji zmiňovaných

finančních poměrových ukazatelů, které byly vhodné pro předpovídání finančních potíží (7).

Práce Edwarda I. Altmana a Gabriele Sabato „Modeling Credit Risk for SMEs: Evidence from the U.S. Market“ se zaměřila na vývoj statistického modelu pro predikci úvěrového rizika malých a středních podniků (SME) ve Spojených státech amerických. Autoři shromáždili data o malých a středních podnicích od roku 1984 do roku 2004, která zahrnovala finanční i nefinanční proměnné, jako je velikost firmy, věk, ziskovost, finanční páka, průmyslový sektor a makroekonomické ukazatele. Tato data použili k vývoji modelu založeného na logistické regresní analýze. Autoři zjistili, že jejich model byl schopen předpovídat úvěrové riziko pro malé a střední podniky s vysokou mírou přesnosti a že proměnné, které úvěrové riziko nejvíce predikovaly, byly ziskovost, pákový efekt a velikost firmy. Autoři také zjistili, že jejich model byl schopen překonat ostatní běžně používané modely úvěrového rizika pro malé a střední podniky. Celkově zdůrazňují důležitost vývoje přesných modelů úvěrového rizika pro malé a střední podniky, které jsou často považovány za rizikovější dlužníky než větší korporace. Vývojem lepších modelů mohou věřitelé činit informovanější rozhodnutí o půjčkách a snížit celkové riziko ve svých úvěrových portfoliích (36).

Podle Kuběnky a Slavíčka modely obvykle vycházejí z vybraných poměrových ukazatelů finanční analýzy, kterým jsou přiřazeny různé významové váhy. Výsledkem modelů je unikátní komplexní hodnota, která je porovnána s hodnotící stupnicí. Výsledná komplexní hodnota, tzv. koeficient hodnocení, zařazuje podnik mezi bankrotní nebo nebankrotující (37).

Bankrotní modely využívají interní informace z účetních výkazů podniků, jako jsou rozvaha, výkaz zisku a ztráty a cash flow, které jsou rozdeleny do pěti hlavních skupin: likvidita, efektivita, nákladová efektivita, zadluženost a ziskovost. Tato analýza má za úkol poskytnout nástroje pro eliminaci potenciálních finančních rizik a pro identifikaci úrovně finančního zdraví podniku (7).

Pro sestavení účetních závěrek platí podnikům povinnost postupovat v souladu s platnými právními předpisy. V České republice mikro a malé účetní jednotky mají výjimku ohledně sestavy účetní závěrky, dle zákona č. 563/1991 Sb., o účetnictví jsou osvobozeny od povinnosti sestavit přehled o peněžních tocích, pokud jejich obrat nepřesahuje 200

milionů Kč a jejich aktiva nejsou vyšší než 100 milionů Kč. Málokterý model bankrotu také využívá informace získané mimo podnikové účetnictví. Zřídka využívají externí informace o ekonomických trendech v zemi, ve které společnost působí, nebo se zaměřují na vývoj konkrétního odvětví. Obecně lze říci, že data potřebná pro konkrétní bankrotní model jsou snadno dostupná, což ovlivňuje míru využití takových modelů v praxi (38).

V této podkapitole budou uvedeny a popsány různé modely pro predikci bankrotu malých a středních podniků ve zpracovatelském průmyslu v České republice a Slovenské republice, pak ty modely budou testovány a poslouží jako inspirace pro tvorbu vlastního modelu.

1.7.1 SME 2 model

Daný model vznik v roce 2010 na základě modelu SME autorů Altmana a Sabato, a pák doplněna společně s N.Wilsonem. Vytvoření modelu SME 2 navazuje na předchozí studii Altmana a Sabato, ve kterém ukázali nutnost oddělit malé a střední firmy od velkých korporací při predikování bankrotu. Model byl vytvořen pomocí diskriminační analýzy. Testování modelu malých a středních podniků Altmana a Sabato bylo rozšířeno na geograficky odlišném vzorku (společnosti ve Spojeném království), včetně extrémně velkého počtu malých společností (5,8 milionu) za relativně nedávné ekonomické období (2000–2007). Tím konečně prokázali významnou spolehlivost a významnou prediktivní schopnost tohoto společného základního prognostického modelu pro malé a střední podniky, která činila 75 % (39).

Poté poprvé zkoumali přidanou hodnotu nefinančních informací speciálně pro malé a střední podniky. S využitím dostupných informací vyvíjeli výchozí prognostický model pro velkou podmnožinu malých a středních podniků, pro které jsou finanční informace velmi omezené (např. živnostníci, profesionálové, mikro společnosti, společnosti, které se rozhodnou pro zjednodušené účetnictví nebo daňové výkaznictví). Zjistili, že tyto informace, pokud jsou k dispozici, mohou výrazně zlepšit přesnost předpovědi modelu až o 13 % (39).

Model SME 2 (39):

$$Z = -0,093388 * X_1 - 1,091555 * X_2 - 0,051342 * X_3 - 0,095322 * X_4 + 0,208167 * X_5 + 1,569317 * X_6 - 0,000046 * X_7 - 0,001057 * X_8 - 0,000273 * X_9 + 0,303799 * X_{10} - 7,554463$$

kde

$$X_1 = \frac{\text{nerozdelený zisk}}{\text{celková aktiva}}$$

$$X_2 = \frac{\text{peněžní prostředky + pohledávky}}{\text{oběžná aktiva}}$$

$$X_3 = \frac{\text{čistá hotovost}}{\text{čisté jmění}}$$

$$X_4 = \text{běžná likvidita}$$

$$X_5 = \frac{\text{závazky z obchodních vztahů}}{\text{cizí zdroje}}$$

$$X_6 = \frac{\text{pohledávky z obchodních vztahů}}{\text{celková aktiva}}$$

$$X_7 = \frac{\text{zásoby}}{\text{pracovní kapitál}}$$

$$X_8 = \text{změna čistého jmění}$$

$$X_9 = \text{změna } X_1$$

$$X_{10} = \log \text{celková aktiva}$$

1.7.2 Model Lugovskaya

Model byl vytvořen na základě lineární diskriminační analýzy v roce 2009 ve Spojeném království na Westminsterské univerzitě autorkou Lyudmilou Lugovskayou. Při vytváření tohoto modelu autorka zkoumala data ruských malých a středních podniků za období připadající na krizi roku 2009. Ve vzorku bylo použito 8 967 podniků (584 bankrotních, 8383 zdravých) (40).

Základní model obsahuje pouze finanční poměrové ukazatele, jiná verze modelu je rozšířena přidáním proměnných velikosti a věku, které nejsou finančními ukazateli. Likvidita a rentabilita jsou klíčovými faktory při předpovídání selhání v daném modelu.

Výsledný model má vysokou prediktivní přesnost a má potenciál praktického využití pro malé a střední podniky (40).

Model Lugovskaya zahrnující jenom finanční ukazatele vypadá takto (40):

$$Z_L = -0,05 - 0,61 * R_{41} + 0,07 * R_{42} + 0,34 * R_{43} - 1,13 * R_{44} + 1,35 * R_{45} + 8,42 * R_{46}$$

kde

$$R_{41} = \frac{\text{peněžní prostředky}}{\text{krátkodobé závazky}}$$

$$R_{42} = \frac{\text{oběžná aktiva}}{\text{krátkodobé závazky}}$$

$$R_{43} = \frac{\text{peněžní prostředky} + \text{krátkodobé pohledávky}}{\text{krátkodobé závazky}}$$

$$R_{44} = \frac{\text{peněžní prostředky} + \text{krátkodobé pohledávky}}{\text{celková aktiva}}$$

$$R_{45} = ROA = \frac{\text{výsledek hospodaření po zdanění}}{\text{celková aktiva}}$$

$$R_{46} = \frac{\text{peněžní prostředky}}{\text{celková aktiva}}$$

Přesnost modelu činila 79 %.

1.7.3 Model Conan & Holder

Model Conan & Holder, který byl vyvinut v roce 1973 na vzorku 190 malých a středních francouzských podniků v letech 1970-1975, z nichž polovina zkrachovala o tři roky dříve. V tomto modelu se používá diskriminační analýza, která má široké praktické uplatnění při predikci bankrotu a spočívá v nalezení lineární kombinace finančních ukazatelů (funkce Z), která umožňuje odlišit zkrachovalé podniky od podniků bez finančních potíží. Funkce skóre obsahuje pět proměnných a je následující (41):

$$Z_{C\&H} = 0,16 * R_{51} + 0,22 * R_{52} - 0,87 * R_{53} - 0,1 * R_{54} + 0,24 * R_{55}$$

kde

$$R_{51} = \frac{\text{oběžná aktiva} - \text{zásoba}}{\text{krátkodobé závazky}}$$

$$R_{52} = \frac{\text{základní kapitál} + \text{dlouhodobé závazky}}{\text{celková aktiva}}$$

$$R_{53} = \frac{\text{úrokové náklady}}{\text{krátkodobé} + \text{dlouhodobé závazky}}$$

$$R_{54} = \frac{\text{náklady na zaměstnance}}{\text{přidaná hodnota}}$$

$$R_{55} = \frac{\text{obchodní marže}}{\text{krátkodobé} + \text{dlouhodobé závazky}}$$

Na základě tohoto modelu je riziko bankrotu podniku podle hodnoty funkčního skóre oceněna v tabulce č. 1.

Tabulka č. 3: Riziko bankrotu podniku

(Vlastní zpracování dle 41)

Hodnota Z-skóre	Situace podniku	Pravděpodobnost bankrotu (%)
Z > 0,16	Výborně	< 10
0,1 < Z < 0,16	Dobře	10 → 30
0,04 < Z < 0,1	Výstraha	30 → 65
-0,05 < Z < 0,04	Nebezpečí	65 → 90
Z < -0,05	Selhaní	> 90

1.7.4 Model Gediminas Šlefendorfas

Nejprve byl model vyvinut na základě podmínek litevských společností. Studie ukázala, že nejběžnějším typem společností v Litvě jsou společnosti s ručením omezeným, takže hlavním cílem bylo analyzovat finanční informace těchto společností a na základě těchto výsledků vytvořit nový model prognózování bankrotu, který bude předpovídat pravděpodobnost bankrotu jako co nejpřesněji. Jako primární vzorek bylo vybráno 145 litevských společností (73 již v úpadku a 72 aktivních) a pomocí krokové metody vícerozměrné diskriminační analýzy byla sestavena lineární funkce ZGS. Za tímto účelem bylo jako primární vstupy zkoumáno 156 různých finančních ukazatelů zkrachovaných a stále fungujících společností, a na základě metody Mann-Whitney U-test bylo vybráno 8 ukazatelů, které jsou v modelu. Výsledky ukázaly, že 89 % společností

bylo klasifikováno správně, což naznačuje, že model je dostatečně silný, aby s dostatečnou přesností předpověděl pravděpodobnost bankrotu společnosti s ručením omezeným působícím v Litvě (42):

$$ZGS = 1,739 + 1,45 * \frac{X1_t - X1_{t-1}}{X1_{t-1}} + 0,922 * \frac{X2_{t-3} - X2_{t-4}}{X1_{t-4}} + 1,307 * \frac{X3_t}{X1_t} - 1,491 \\ * \frac{X4_{t-4}}{X5_{t-4}} - 0,677 * \frac{X6_{t-5}}{X7_{t-5}} + 1,257 * \frac{\frac{X8_{t-2}}{X1_{t-2}} - \frac{X8_{t-4}}{X1_{t-4}}}{\frac{X8_{t-4}}{X1_{t-4}}} - 0,246 \\ * \frac{\frac{X2_{t-2}}{X1_{t-2}} - \frac{X2_{t-5}}{X1_{t-5}}}{\frac{X2_{t-5}}{X1_{t-5}}}$$

kde

X_1 = tržby

X_2 = provozní náklady

X_3 = provozní výnosy

X_4 = celková pasiva

X_5 = celková aktiva

X_6 = EAT = zisk po zdanění

X_7 = vlastní kapitál

X_8 = náklady z finančního majetku

t = sledovaný rok

ZGS = koeficient predikce bankrotu pro rok $t + 1$

1.7.5 Model Tereshchenko

Nejběžnější na Ukrajině je diagnostika bankrotu podniku podle modelu Tereshchenka, který byl vytvořen v roce 2003. Podle názoru ukrajinského ekonoma Tereshchenko by optimální diskriminační funkce měla zohledňovat všechny složky finančního stavu: likviditu, ziskovost, obrat, strukturu majetku, kapitálu atd. Tento model je často používaný pro ukrajinské podniky různé velikosti.

Model Tereshchenko existuje ve dvou verzích. První je univerzální model, který obsahuje 6 ukazatelů a je postaven na základě dat z 850 podniků různých odvětví. Druhý model obsahuje 10 ukazatelů a zohledňuje diferenciaci podniků podle odvětví (43).

Tereshchenkův model je prezentován takto (43):

$$Z_{TEP} = 1,5 * X_1 + 0,08 * X_2 + 10 * X_3 + 5 * X_4 + 0,3 * X_5 + 0,1 * X_6$$

kde

X_1 = běžná likvidita z Cash flow = poměr Cash flow z provozní činnosti ke krátkodobým závazkům

X_2 = poměr celkových aktiv ke krátkodobým závazkům

X_3 = ROA = poměr zisku po zdanění k celkovým aktivům

X_4 = ROS = poměr zisku po zdanění k tržbám

X_5 = obrat zásob = poměr zásob k tržbám

X_6 = obrat celkových aktiv = poměr tržeb k celkovým aktivům

Stupnice pro určení stavu podniku podle vzoru O. Tereshchenka (43):

pokud:

$Z_{TEP} > 2$ – bankrot bezprostředně nehrozí,

$1 < Z_{TEP} < 2$ – finanční stabilita je narušena,

$0 < Z_{TEP} < 1$ – hrozí bankrot

Je možné si všimnout hlavních výhod diskriminačního modelu Tereshchenko: model se snadno používá a je vyvíjen pomocí domácích statistických údajů; je zohledněna moderní mezinárodní praxe; díky použití různých modifikací základního modelu pro podniky různých typů činnosti jsou řešeny problémy kritických hodnot ukazatelů; zohledňuje odvětvová specifika podniků. Tato technika však není dokonalá a má své nedostatky: nedostatek hloubkové klasifikace stability finanční situace (existuje pouze uspokojivá a neuspokojivá finanční situace); široký interval nejistoty, který vyžaduje další analýzu k identifikaci stability finanční situace; nedostatečné teoretické zdůvodnění kritických

bodů (nebo intervalů) u jednotlivých finančních ukazatelů, což vede k nepřesnostem při stanovování normativních hodnot finančních ukazatelů (43).

Na základě výše uvedeného lze konstatovat, že ukazateli úpadku podniku jsou v prvé řadě struktura majetku, likvidita a rentabilita podniku. Optimální model pro predikci pravděpodobnosti bankrotu by tedy měl obsahovat následující ukazatele podle autora (43):

- rentabilita vlastního kapitálu – dynamika tohoto ukazatele ovlivňuje tržní hodnotu akcií společnosti;
- koeficient finanční autonomie;
- koeficient běžné likvidity – výše tohoto koeficientu závisí na odvětví výroby;
- trvaní výrobního cyklu atd;
- ukazatel obratu aktiv;
- rentabilita tržeb.

Souhrnně lze konstatovat, že výše uvedené modely jsou přímo určeny pro studium malých a středních podniků, což je v souladu s tématem této práce. Všechny modely byly vytvořeny na základě diskriminační analýzy ve formě lineární funkce. Každý z těchto modelů byl vytvořen v různých zemích s použitím dat konkrétní země a testován v různých obdobích, což je obzvláště zajímavé při jejich studiu na datech českých společností.

2 ZHODNOCENÍ SOUČASNÉ EFEKTIVNOSTI VYBRANÝCH BANKROTNÍCH MODELŮ NA ZKOUMANÉM VZORKU PODNIKŮ

Tato kapitola diplomové práce se zaměřuje na pečlivě vybrané modely predikce bankrotu, které byly podrobně popsány v teoretické části. Konkrétně se jedná o modely SME 2, Lugovskaya, Conan & Holder, Gediminas Šlefendorfas a Tereshchenko. Důraz je kladen na představení a vyhodnocení spolehlivosti těchto modelů pomocí testování. Pro testy byl použit vzorek složený z malých a středních podniků podle CZ-NACE C – Zpracovatelský průmysl v České republice a Slovenské republice. Data pro testování byla získána z databáze Orbis Europe.

Vzorek se skládá z celkem 497 podniků, z nichž 99 jsou bankrotní a 398 jsou aktivní podniky. V analýze byla použita data z období pěti let, kde označení "t" představuje poslední rok existence firmy (tj. u bankrotních podniků rok bankrotu), "t-1" představuje rok před bankrotom a tak dále. Výběr vzorku byl proveden s ohledem na skutečnost, že počet aktivních firem v odvětví je několikanásobně vyšší než počet bankrotních firem. Je třeba poznamenat, že vzorek je poměrně omezený, protože velký počet podniků v tomto rozsahu vykazuje ve zjednodušené podobě, což vytváří určité problémy při výpočtu ukazatelů pro modely.

Pro úspěšné testování je stanovena hranice přesnosti 50 %. Pokud model nedosáhne této hranice, je považován za nespolehlivý a nelze jej použít pro sestavení vlastního modelu. V rámci této kapitoly bude provedeno podrobné představení a vyhodnocení spolehlivosti každého testovaného modelu. Přesnost byla měřená jako true positive rate. Jedná se o poměr skutečně pozitivních případů, které byly správně klasifikovány jako pozitivní, ke všem pozitivním případům v souboru dat. Tato metrika vyjadřuje schopnost klasifikačního modelu správně identifikovat pozitivní případy. Čím vyšší je true positive rate, tím lépe model rozpoznává pozitivní případy a tím je spolehlivější.

2.1 Přesnost modelu SME 2

Přesnost modelu byla spočítána na základě určitých kritérií, které jsou uvedeny na začátku kapitoly. Tabulka zobrazuje přesnost modelu pro predikci bankrotu podniků. Data

pro výpočet přesnosti byla použita pro 497 podniků, což je výrazně méně, než bylo použito při tvorbě modelu. Proto je možné, že celková přesnost modelu v této situaci bude nižší než u modelu, který byl vytvořen s větším množstvím dat.

Tabulka č.4 obsahuje relativní hodnoty přesnosti v různých časových obdobích (t, t-1, t-2, t-3, t-4, kde t je rok před bankrotem, stejně tak t-4 je pět let před bankrotem) a celkovou přesnost za celé období. První tři řádky zobrazují počet platných pozorování aktivních a bankrotních podniků v jednotlivých obdobích, a také šedou zónu.

Správná klasifikace znamená, že podnik byl správně zatřízen v souladu s jeho statusem (aktivní/bankrotní). Do šedé zóny spadají podniky, které byly špatně kvalifikovány tzn., že jejich hodnota při vypočtu modelu v důsledku odpovídala bankrotní i když podnik je aktivní.

Tabulka č. 4: Přesnost testování aktivních a bankrotních podniků při modelu SME 2

(Zdroj: Vlastní zpracování dle databáze Orbis Europe)

Přesnost		Přesnost	t	t-1	t-2	t-3	t-4	Celková	
Správně klasifikované podniky	aktivní	absolutně	328	318	309	295	293		
		relativně, %	82	80	78	74	74	78	
	bankrotní	absolutně	78	69	58	61	74		
		relativně, %	79	70	59	62	75	69	
Špatně klasifikované podniky	aktivní	absolutně	70	80	89	103	105		
		relativně, %	18	20	22	26	26	22	
	bankrotní	absolutně	21	30	38	25	25		
		relativně, %	21	30	38	25	25	28	
Celková, %			81	75	68	68	74	73	
Podle autora, %			-	-	-	-	-	75	

Celková přesnost v posledních pěti obdobích se pohybuje mezi 68 % a 81 %, s průměrnou přesností 73 %, přičemž je nad hodnotou 50 %. Autory modelu uvádí, že přesnost predikce v jejich studii byla 75 %, což je blízko průměrné hodnotě v tabulce. Dále lze doplnit, že model s větší přesností rozeznává aktivní podniky než bankrotní, což naznačuje, že má tendenci klasifikovat více podniků jako aktivní než jako bankrotní.

2.2 Přesnost modelu Lugovskaya

Původně model byl testován na 8 967 podnicích při jeho tvorbě, tentokrát bylo použito 497 podniků. V tabulce č. 5 je uvedena přesnost pro aktivní a bankrotní podniky stejně jako u předchozího modelu.

Z výsledků tabulky vyplývá, že celková přesnost modelu je 64 %. Podle autorky má model přesnost 79 %. Model lze považovat za spolehlivý s tím, že dosahuje přesnosti vyšší než 50 %. Podobně jako předchozí model, i tento model má lepší schopnost rozpoznat aktivní podniky než bankrotní.

Tabulka č. 5: Přesnost testování aktivních a bankrotních podniků při modelu Lugovskaya

(Zdroj: Vlastní zpracování dle databáze Orbis Europe)

	Přesnost	Přesnost	t	t-1	t-2	t-3	t-4	Celková
Správně klasifikované podniky	aktivní	absolutně	322	319	316	323	334	
		relativně, %	81	80	79	81	84	81
	bankrotní	absolutně	59	46	42	43	45	
		relativně, %	60	46	42	43	45	47
Špatně klasifikované podniky	aktivní	absolutně	76	79	82	75	64	
		relativně, %	19	20	21	19	16	19
	bankrotní	absolutně	40	53	57	56	54	
		relativně, %	40	54	58	57	55	53
Celková, %			70	63	61	62	65	64
Podle autora, %			-	-	-	-	-	79

2.3 Přesnost modelu Conan & Holder

Model Conan & Holder byl testován na 190 vzorcích malých podniků. V tabulce č. 6 je zobrazena přesnost pro aktivní a bankrotní podniky.

Celková přesnost modelu se pohybovala mezi 51 % a 62 %, podle autora 79 %. Je třeba mít na paměti, že přesnost modelu se může lišit v závislosti na datové sestavě, na které byl testován. Nicméně z výsledků lze usoudit, že model se zdá být poměrně spolehlivý v predikci bankrotů aktivních podniků, zatímco v predikci bankrotů podniků je přesnost nižší.

Tabulka č. 6: Přesnost testování aktivních a bankrotních podniků při modelu Conan & Holder

(Zdroj: Vlastní zpracování dle databáze Orbis Europe)

Přesnost	Přesnost	t	t-1	t-2	t-3	t-4	Celková
Správně klasifikované podniky	aktivní	absolutně	319	312	297	307	304
		relativně, %	80	78	75	77	76
	bankrotní	absolutně	44	33	30	26	25
		relativně, %	44	33	30	26	25
Špatně klasifikované podniky	aktivní	absolutně	79	86	101	91	94
		relativně, %	20	22	25	23	24
	bankrotní	absolutně	55	66	69	73	74
		relativně, %	56	67	70	74	75
Celková, %				52	52	51	55
Podle autora, %				-	-	-	79

2.4 Přesnost modelu Gediminas Šlefendorfas

Tento model původně byl testován na 145 litevských podnicích. Klasifikace byla stanovena takovým způsobem, že za aktivní podnik byl považován ten, který měl hodnotu více než 1, za bankrotní s hodnotou 0 a méně. V tabulce č. 7 je uvedena přesnost pro aktivní a bankrotní podniky.

Tabulka č. 7: Přesnost testování aktivních a bankrotních podniků při modelu Gediminas Šlefendorfas

(Zdroj: Vlastní zpracování dle databáze Orbis Europe)

Přesnost	Přesnost	t
Správně klasifikované podniky	aktivní	absolutně 372
		relativně, % 99
	bankrotní	absolutně 71
		relativně, % 72
Špatně klasifikované podniky	aktivní	absolutně 5
		relativně, % 1
	bankrotní	absolutně 28
		relativně, % 28
Celková, %		85
Podle autora, %		89

Celková přesnost je 85 %, proto lze uvažovat, že tento model má dostatečnou vypovídací schopnost.

2.5 Přesnost modelu Tereshchenko

Model Tereshchenko byl testován na 850 vzorcích. Klasifikace byla spočítána na základě hodnot, kde více než 2 je aktivní podnik, méně než 1 je bankrotní. V tabulce je uvedena přesnost pro aktivní a bankrotní podniky.

Tabulka č. 8: Přesnost testování aktivních a bankrotních podniků při modelu Tereshchenko

(Zdroj: Vlastní zpracování dle databáze Orbis Europe)

Přesnost	Přesnost	t	t-1	t-2	t-3	t-4	Celková
Správně klasifikované podniky	aktivní	absolutně	295	284	306	312	314
		relativně, %	74	71	77	78	79
	bankrotní	absolutně	76	76	64	61	65
		relativně, %	77	77	65	62	66
Špatně klasifikované podniky	aktivní	absolutně	103	114	92	85	83
		relativně, %	26	29	23	21	21
	bankrotní	absolutně	23	23	35	38	34
		relativně, %	23	23	35	38	34
Celková, %				71	70	72	73
Podle autora, %				-	-	-	79

Celková přesnost je 73 %, proto lze uvažovat, že tento model má dostatečnou vypovídací schopnost a celková přesnost odpovídá stanovené podle autora. Během období jednoho roku před bankrotem a roku bankrotu tento model lépe rozpoznává bankrotní podniky než aktivní, ale s rostoucím časovým odstupem od roku bankrotu model lepe klasifikuje aktivní podniky než bankrotní.

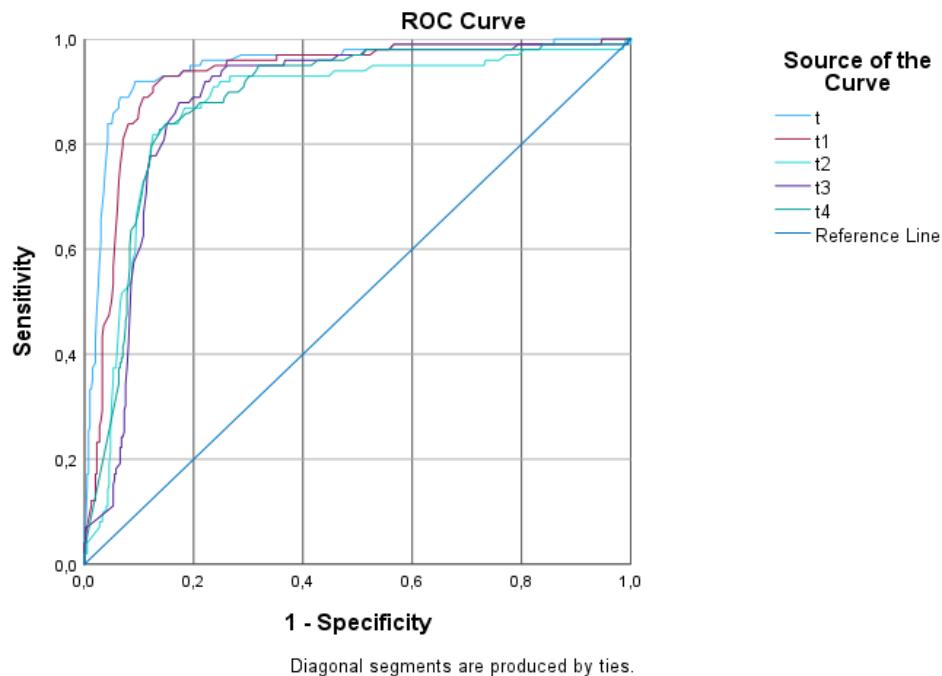
2.6 ROC křivky vybraných modelů

V této podkapitole bude zkoumána přesnost vybraných modelů pomocí ROC křivky a plochy pod křivkou AUC v statistickém programu IBM SPSS. ROC křivka a AUC (Area Under Curve) jsou nástroje pro vyhodnocení kvality klasifikačních modelů. ROC křivka graficky zobrazuje vztah mezi mírou citlivosti a mírou specifičnosti pro různé hodnoty klasifikace. AUC je plocha pod touto křivkou a vyjadřuje celkovou úspěšnost modelu, přičemž hodnota AUC 0,5 odpovídá náhodné klasifikaci a hodnota 1 dokonalému

modelu. Pokud hodnota p-hodnota testu nepřekračuje 0,05, považuje se výsledek za významný.

2.6.1 ROC křivka modelu SME 2

Na grafu č je zobrazena ROC křivka modelu SME 2 na základě spočítaných hodnot u aktivních a bankrotních podniků za 5 let. V tabulce č. je uvedena data plochy pod křivkou AUC.



Graf č. 5: ROC křivka – model SME 2

(Zdroj: vlastní zpracování dle IBM SPSS)

Podle grafu hodnoty pohybují od 0,871 pro období t-2 až po 0,949 pro období t. Vyšší hodnota plochy pod křivkou znamená lepší vyhodnocení modelu v rozlišování mezi aktivními a bankrotními podniky.

Všechny hodnoty v této tabulce jsou statisticky významné, protože mají p-hodnotu nižší než 0,05.

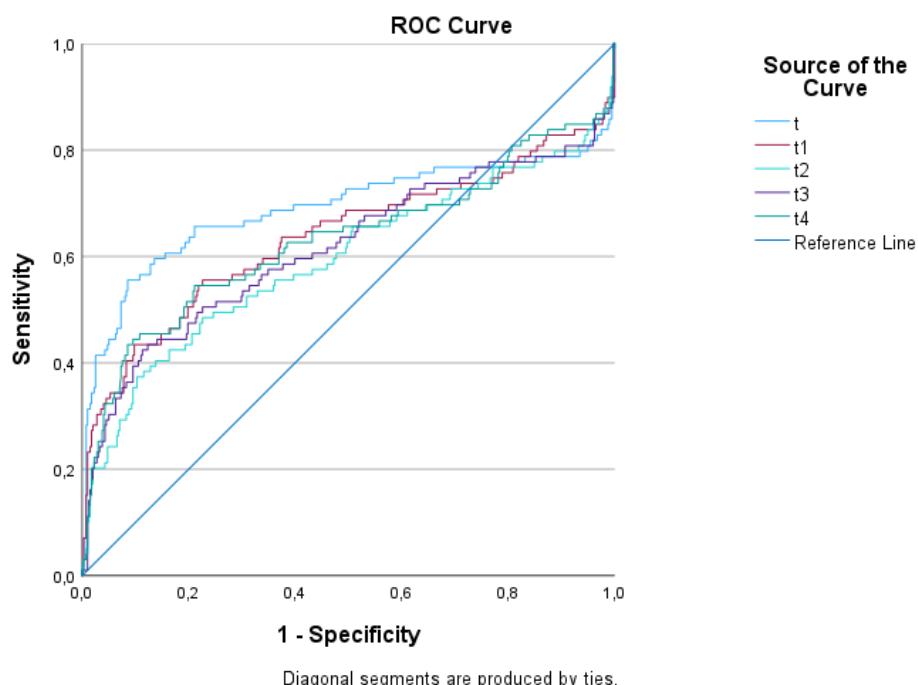
Tabulka č. 9: Plocha pod ROC křivkou – model SME 2

(Zdroj: vlastní zpracování dle IBM SPSS)

Období	Plocha pod křivkou	p-hodnota	95% interval spolehlivosti	
			Spodní hranice	Horní hranice
t	0,949	0,000	0,924	0,975
t-1	0,926	0,000	0,897	0,956
t-2	0,871	0,000	0,828	0,913
t-3	0,880	0,000	0,844	0,915
t-4	0,884	0,000	0,848	0,920

2.6.2 ROC křivka modelu Lugovskaya

Stejným způsobem byl testován model Lugovskaya.



Graf č. 6: ROC křivka – model Lugovskaya

(Zdroj: vlastní zpracování dle IBM SPSS)

Hodnoty podle výsledku ROC křivky a plochy pod křivkou jsou v tomto případě nižší než v předchozí tabulce, což naznačuje horší kvalitu klasifikačního modelu.

Tabulka č. 10: Plocha pod ROC křivkou – model Lugovskaya

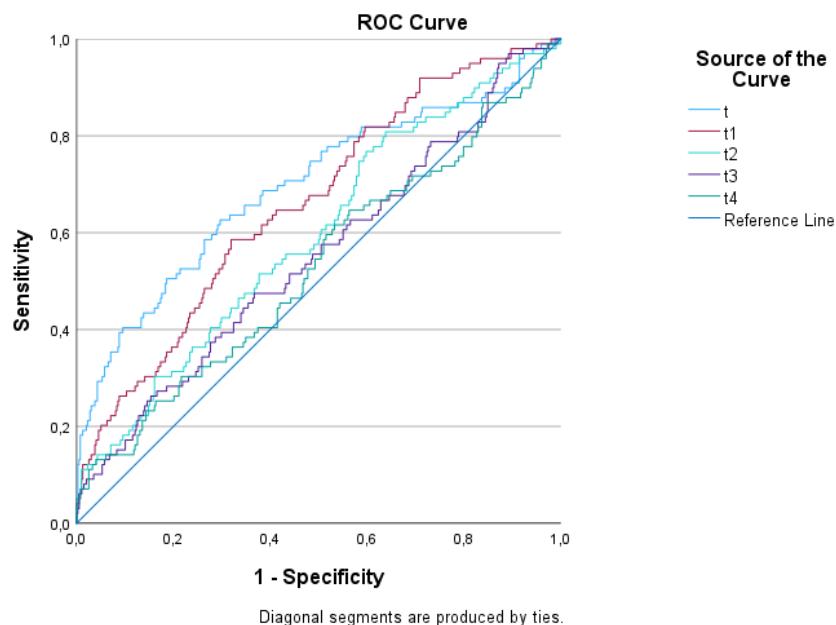
(Zdroj: vlastní zpracování dle IBM SPSS)

Období	Plocha pod křivkou	p-hodnota	95% interval spolehlivosti	
			Spodní hranice	Horní hranice
t	0,690	0,000	0,612	0,769
t-1	0,637	0,000	0,560	0,713
t-2	0,594	0,004	0,518	0,670
t-3	0,616	0,000	0,540	0,692
t-4	0,630	0,000	0,554	0,706

Tento model vykazuje nižší hodnotu než předchozí model, ale stejně má statistické významné hodnoty.

2.6.3 ROC křivka modelu Conan & Holder

Na dalším grafu je zobrazena ROC křivka modelu Conan & Holder.



Graf č. 7: ROC křivka – model Conan & Holder

(Zdroj: vlastní zpracování dle IBM SPSS)

Z výsledků lze vidět, že plocha pod křivkou se postupně snižuje od období t až po období t-4. Období t má nejvyšší plochu pod křivkou 0,696 a nejnižší p-hodnotu 0,000, což

znamená, že je nejlepším obdobím pro predikci klasifikačního modelu. Období t-4 má nejnižší plochu pod křivkou 0,529 a nejvyšší p-hodnotu 0,365, což znamená, že je nejhorším obdobím pro predikci klasifikačního modelu.

Tabulka č. 11: Plocha pod ROC křivkou – model Conan & Holder

(Zdroj: vlastní zpracování dle IBM SPSS)

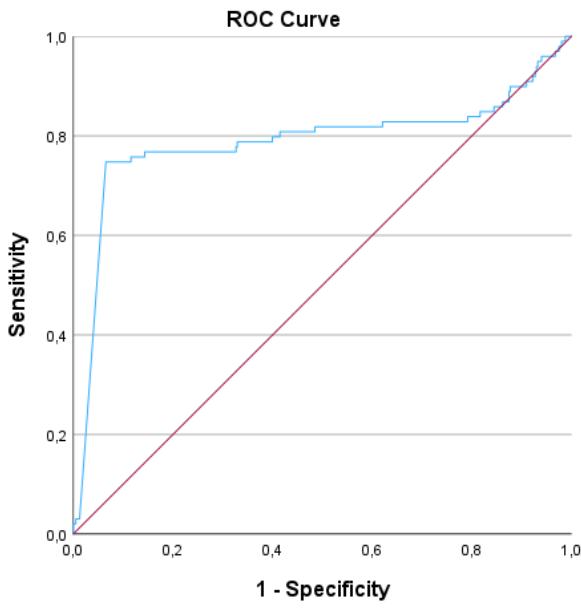
Období	Plocha pod křivkou	p-hodnota	95% interval spolehlivosti	
			Spodní hranice	Horní hranice
t	0,696	0,000	0,631	0,760
t-1	0,661	0,000	0,602	0,720
t-2	0,595	0,003	0,532	0,658
t-3	0,553	0,104	0,487	0,618
t-4	0,529	0,365	0,463	0,596

Výsledky tedy naznačují, že predikční schopnosti klasifikačního modelu se postupně zhoršují v průběhu času. Model lze uvažovat za spolehlivý, protože jeho hodnota přesahuje hranici 0,50. Model je statisticky nevýznamný v období t-3 a t-4 podle p-hodnoty. V ostatních obdobích je p-hodnota pod hranici 0,05, což znamená, že jsou významné.

2.6.4 ROC křivka modelu Gediminas Šlefendorfas

Na grafu je znázorněna ROC křivka modelu Gediminas Šlefendorfas jeden rok, protože tento model počítá data za více let v rámci jednoho ukazatele, jiné modely počítají data za jeden rok v rámci jednoho ukazatele.

Hodnota podle ROC křivky a plochy pod křivkou dosahuje 0,788, což plně odpovídá kritériu stanovenému na začátku kapitoly – nad 0,50. P-hodnota nepřesahuje hodnotu 0,05 a považujeme hodnotu za statisticky významnou.



Graf č. 8: ROC křivka – model Gediminas Šlefendorfas

(Zdroj: vlastní zpracování dle IBM SPSS)

Tabulka č. 12: Plocha pod ROC křivkou – model Gediminas Šlefendorfas

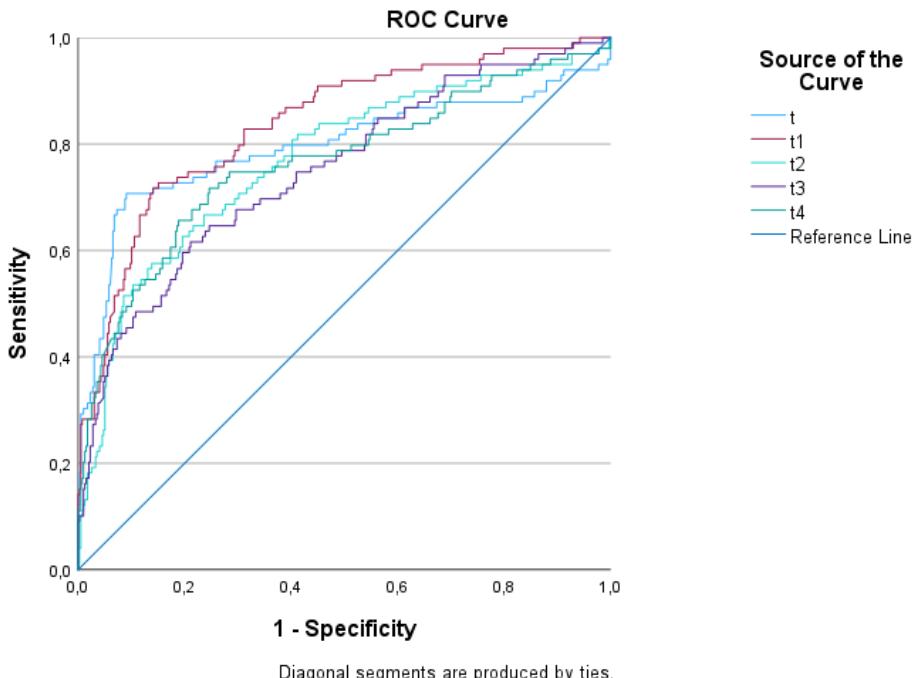
(Zdroj: vlastní zpracování dle IBM SPSS)

Období	Plocha pod křivkou	p-hodnota	95% interval spolehlivosti	
			Spodní hranice	Horní hranice
t	0,788	0,000	0,721	0,855

Na základě dosažených výsledků model lze považovat za spolehlivý.

2.6.5 ROC křivka modelu Tereshchenko

Na grafu č je zobrazena ROC křivka modelu Tereshchenko na základě spočítaných hodnot u aktivních a bankrotních podniků za 5 let. V tabulce č.11 je uvedena data plochy pod křivkou (AUC).



Graf č. 9: ROC křivka – model Tereshchenko

(Zdroj: vlastní zpracování dle IBM SPSS)

Tabulka č. 13: Plocha pod ROC křivkou – model Tereshchenko

(Zdroj: vlastní zpracování dle IBM SPSS)

Období	Plocha pod křivkou	p-hodnota	95% interval spolehlivosti	
			Spodní hranice	Horní hranice
t	0,796	0,000	0,733	0,859
t-1	0,838	0,000	0,792	0,885
t-2	0,770	0,000	0,713	0,826
t-3	0,750	0,000	0,693	0,807
t-4	0,765	0,000	0,705	0,825

Hodnota ROC a AUC se pohybuje v rozmezí 0,750 – 0,838 v průběhu 5 let, p-hodnota je pod hranici 0,05. Model je spolehlivý.

2.7 T-test vybraných proměnných

V této části diplomové práce byly testovány vybrané proměnné pomocí t-testu. Data obsahují proměnné z vybraných modelů a 497 vzorků malých a středních podniků ve zpracovatelském průmyslu, z nichž 99 jsou bankrotní a 398 jsou aktivní podniky. Pro

testování bylo použito období rok před bankrotem. Testování proměnných bylo provedeno pomocí statistického programu IBM SPSS. V prvním kroku se používá Levenův test, který testuje rovnost rozptylů mezi skupinami. Dalším krokem je Studentův a Welchův t-test. Pokud jsou rozptyly stejné, je vhodné použít Studentův t-test, který porovnává průměry mezi skupinami. Pokud jsou však rozptyly různé, používá se Welchův t-test, který bere v úvahu různé rozptyly a porovnává průměry mezi skupinami. Rozhodnutí o volbě Studentova nebo Welchova testu závisí na výsledcích Levenova testu, zejména na hodnotě p-hodnoty (sig.). Pokud je p-hodnota větší než 0,05, pak se předpokládá, že rozdíly v rozptylech mezi skupinami nejsou významné a používá se Studentův t-test. Pokud je p-hodnota menší než 0,05, pak se předpokládá, že rozdíly v rozptylech mezi skupinami jsou významné a používá se Welchův t-test.

2.7.1 T-test ukazatele modelu SME 2

Z výsledků v tabulce lze vyvodit, že rozptyly pro všechny proměnné jsou signifikantně odlišné, a proto se používá Welchův t-test. Proměnné (peněžní prostředky+pohledávky)/oběžná aktiva, běžná likvidita, pohledávky z obchodních vztahů/celková aktiva, změna čistého jmění, log celková aktiva vykazují signifikantní rozdíly mezi průměry mezi dvěma soubory dat. Naopak proměnné závazky z obchodních vztahů/cizí zdroje a zásoby/pracovní kapitál nevykazují signifikantní rozdíly mezi průměry mezi dvěma soubory dat. Ostatní považujeme za statisticky nevýznamné podle t-testu.

Tabulka č. 14: T-test – model SME 2

(Zdroj: vlastní zpracování dle IBM SPSS)

Proměnné	Levenův test		Studentův t-test			Welchův t-test		
	F	Sig.	T	Df	P	T	Df	P
nerozdelený zisk / celková aktiva	32,014	0,000	3,291	495	0,001	1,636	98,001	0,105
(peněžní prostředky + pohledávky) / oběžná aktiva	96,008	0,000	-5,725	495	0,000	-4,042	112,316	0,000
čistá hotovost / čisté jmění	27,092	0,000	2,725	495	0,003	1,446	99,812	0,151
běžná likvidita	21,161	0,000	4,423	495	0,000	7,828	490,402	0,000
závazky z obchodních vztahů / cizí zdroje	4,003	0,046	-1,163	495	0,245	-1,009	129,871	0,315
pohledávky z obchodních vztahů / celková aktiva	168,615	0,000	-7,473	495	0,000	-4,611	105,269	0,000
zásoby / pracovní kapitál	0,037	0,848	0,607	495	0,544	1,059	483,894	0,290
změna čistého jmění	10,747	0,001	5,565	495	0,000	2,834	98,634	0,006
změna (nerozdelený zisk / celková aktiva)	20,061	0,000	-2,353	495	0,019	-1,170	98,000	0,245
log celková aktiva	415,673	0,000	29,294	495	0,000	15,506	99,729	0,000

2.7.2 T-test ukazatele modelu Lugovskaya

V tabulce můžeme vidět, že hodnoty F v Levenově testu jsou velmi malé pro všechny proměnné, což naznačuje, že rozptyly jsou různé. U skoro všech proměnných jsou pravděpodobnosti menší než 0,05, což znamená, že shoda rozptylů je signifikantní, kromě peněžní prostředky / celková aktiva podle výpočtu.

Tabulka č. 15: T-test – model Lugovskaya

(Zdroj: vlastní zpracování dle IBM SPSS)

Proměnné	Levenův test		Studentův t-test			Welchův t-test		
	F	Sig.	T	Df	P	T	Df	P
peněžní prostředky / krátkodobé závazky	15,633	0,000	2,882	495	0,002	5,657	432,361	0,000
oběžná aktiva / krátkodobé závazky	21,161	0,000	4,423	495	0,000	7,828	490,402	0,000
(peněžní prostředky + krátkodobé pohledávky) / krátkodobé závazky	12,600	0,000	3,102	495	0,001	5,191	449,741	0,000
(peněžní prostředky + krátkodobé pohledávky) / celková aktiva	96,008	0,000	-5,725	495	0,000	-4,042	112,316	0,000
ROA	90,471	0,000	6,174	495	0,000	3,092	98,184	0,001
peněžní prostředky / celková aktiva	26,647	0,000	-0,042	495	0,967	-0,028	109,038	0,978

2.7.3 T-test ukazatele modelu Conan & Holder

Podle výsledků v tabulce, lze považovat za statisticky významné pouze proměnné (oběžná aktiva-zásoby)/krátkodobé závazky a obchodní marže/(krátkodobé+dlouhodobé závazky) na hladině významnosti 5 %. Ostatní proměnné v tabulce nejsou statisticky významné.

Tabulka č. 16: T-test – model Conan & Holder

(Zdroj: vlastní zpracování dle IBM SPSS)

Proměnné	Levenův test		Studentův t-test			Welchův t-test		
	F	Sig.	T	Df	P	T	Df	P
(oběžná aktiva-zásoby) / krátkodobé závazky	18,404	0,000	-4,653	495	0,000	-8,886	467,049	0,000
(základní kapitál + dlouhodobé závazky) / celková aktiva	31,663	0,000	-3,227	495	0,001	-1,604	98,001	0,112
úrokové náklady / (krátkodobé + dlouhodobé závazky)	2,773	0,096	1,329	495	0,185	2,535	468,027	0,012
náklady na zaměstnance / přidaná hodnota	0,643	0,423	1,711	495	0,088	2,038	196,060	0,043
obchodní marže / (krátkodobé + dlouhodobé závazky)	29,274	0,000	5,289	495	0,000	8,746	437,995	0,000

2.7.4 T-test ukazatele modelu Gediminas Šlefendorfas

V tabulce č. 17 se ukazuje, že skoro všechny proměnné jsou významné pro predikci, s výjimkou proměnné provozní výnosy, u které není statisticky významný rozdíl.

Tabulka č. 17: T-test – model Gediminas Šlefendorfas

(Zdroj: vlastní zpracování dle IBM SPSS)

Proměnné	Levenův test		Studentův t-test			Welchův t-test		
	F	Sig.	T	Df	P	T	Df	P
tržby	7,051	0,008	19,462	495	0,000	21,843	176,986	0,000
provozní náklady	5,698	0,017	17,625	495	0,000	18,243	157,269	0,000
provozní výnosy	2,899	0,089	18,127	495	0,000	18,850	158,238	0,000
celková pasiva	10,291	0,001	21,560	495	0,000	23,642	170,704	0,000
celková aktiva	10,291	0,001	21,560	495	0,000	23,642	170,704	0,000
EAT	15,825	0,000	3,973	495	0,000	6,173	372,367	0,000
vlastní kapitál	10,755	0,001	5,562	495	0,000	2,832	98,633	0,006
náklady z finančního majetku	19,129	0,000	5,112	495	0,000	9,023	489,242	0,000

2.7.5 T-test ukazatele modelu Tereshchenko

Na základě výsledků tabulky č. 18 je vidět, že pouze 2 ukazatele jsou významné – Cash flow z provozní činnosti/krátkodobé závazky a celková aktiva / krátkodobé závazky. Ostatní ukazatele jsou statisticky nevýznamné na 5 % hladině.

Tabulka č. 18: T-test – model Tereshchenko

(Zdroj: vlastní zpracování dle IBM SPSS)

Proměnné	Levenův test		Studentův t-test			Welchův t-test		
	F	Sig.	T	Df	P	T	Df	P
Cash flow z provozní činnosti / krátkodobé závazky	33,856	0,000	6,492	495	0,000	11,340	484,029	0,000
celková aktiva / krátkodobé závazky	27,828	0,000	5,426	495	0,000	9,811	494,984	0,000
ROA	16,706	0,000	2,201	495	0,028	1,094	98,000	0,277
ROS	36,986	0,000	3,368	495	0,001	1,675	98,006	0,097
obrat zásob	5,373	0,021	1,533	495	0,126	0,939	104,964	0,350
obrat celkových aktiv	16,864	0,000	-2,244	495	0,025	-1,116	98,001	0,267

3 NÁVRH VLASTNÍHO BANKROTNÍHO MODELU

Vybraná data zahrnuje 497 malých a středních podniků zpracovatelského průmyslu v České republice a Slovenské republice a byla získána z databáze Orbis Europe. Data byla následně rozdělena do trénovacích a testovacích vzorků pomocí funkcí v MS Excel. Přibližně 70 % dat bylo určeno jako trénovací vzorky pro použití v logistické regresní analýze a zbývajících 30 % bylo určeno jako testovací vzorky. Rozdělení dat bylo provedeno pomocí funkcí „KDYŽ“ a „NÁHČÍSLO“. Funkce NÁHČÍSLO generuje rovnoměrně rozložená náhodná reálná čísla v intervalu 0 až 1 a funkce KDYŽ byla použita k rozhodnutí, zda jednotlivý vzorek bude zařazen do trénovacího nebo testovacího vzorku. Pokud bylo náhodné číslo větší než 0,7, vzorek byl zařazen do trénovacího vzorku, jinak byl zařazen do testovacího vzorku.

3.1 Korelační analýza

V této podkapitole bude provedena korelační analýza, aby bylo možné identifikovat vztahy mezi proměnnými a zjistit, jestli mezi sebou nejsou korelovány - tj. nejsou si dvě proměnné vzájemně hodně podobné. Na základě výsledků T-testu budou následně vybrány pouze ty proměnné, které jsou statisticky významné a budou použity při návrhu vlastního modelu pro predikci bankrotu podniku. Korelační analýza byla provedena v IBM SPSS. Na základě výsledků korelační analýzy byly vyrazeny proměnné, které vykazovaly mezi sebou korelační koeficient vyšší než 0,75, aby nedocházelo ke zkreslení výsledků v analýze logistické regrese.

Tabulka č. 19 obsahuje seznam proměnných, které byly použity při tvorbě jednotlivých bankrotních modelů. Následně budou vyrazeny silně korelované nebo obdobné proměnné a zůstanou pouze ty, které budou splňovat stanovená kritéria pro tvorbu vlastního modelu.

Proměnné z tabulky č. 20 byly vybrány pro tvorbu vlastního modelu. Kritériem je, aby korelace byla nižší než 0,75 a vyšší než -0,75.

Tabulka č. 19: Seznam testovaných proměnných

Model	Proměnná
SME 2	nerozdělený zisk / celková aktiva
	(peněžní prostředky + pohledávky) / oběžná aktiva
	čistá hotovost / čisté jmění
	běžná likvidita
	závazky z obchodních vztahů / cizí zdroje
	pohledávky z obchodních vztahů / celková aktiva
	zásoby / pracovní kapitál
	změna čistého jmění
	změna (nerozdělený zisk / celková aktiva)
	log celková aktiva
Lugovskaya	peněžní prostředky / krátkodobé závazky
	oběžná aktiva / krátkodobé závazky
	(peněžní prostředky + krátkodobé pohledávky) / krátkodobé závazky
	(peněžní prostředky + krátkodobé pohledávky) / celková aktiva
	ROA
Conan & Holder	peněžní prostředky / krátkodobé závazky
	(oběžná aktiva-zásoby) / krátkodobé závazky
	(základní kapitál + dlouhodobé závazky) / celková aktiva
	úrokové náklady / (krátkodobé + dlouhodobé závazky)
	náklady na zaměstnance / přidaná hodnota
Gediminas Šlefendorfas	obchodní marže / (krátkodobé + dlouhodobé závazky)
	tržby
	provozní náklady
	provozní výnosy
	celková pasiva
	celková aktiva
	EAT
Tereshchenko	vlastní kapitál
	náklady z finančního majetku
	Cash flow z provozní činnosti / krátkodobé závazky
	celková aktiva / krátkodobé závazky
	ROA
	ROS
	obrat zásob
	obrat celkových aktiv

Tabulka č. 20: Seznam vybraných proměnných

Model	Proměnná
SME 2	čistá hotovost / čisté jmění
	závazky z obchodních vztahů / cizí zdroje
	pohledávky z obchodních vztahů / celková aktiva
	zásoby / pracovní kapitál
	log celková aktiva
Lugovskaya	peněžní prostředky / krátkodobé závazky
	(peněžní prostředky+ krátkodobé pohledávky) / celková aktiva
	výsledek hospodaření po zdanění / celková aktiva
	peněžní prostředky / celková aktiva
Conan & Holder	(oběžná aktiva-zásoby) / krátkodobé závazky
	úrokové náklady / (krátkodobé + dlouhodobé závazky)
	náklady na zaměstnance / přidaná hodnota
Gediminas Šlefendorfas	tržby
	EAT
	vlastní kapitál
	náklady z finančního majetku
Tereshchenko	Cash flow z provozní činnosti / krátkodobé závazky
	ROS
	obrat zásob

Z celkového počtu proměnných některé byly vyřazeny z výběru, protože vykazovaly příliš silnou korelaci s jinými proměnnými. Například proměnné celková pasiva a celková aktiva mezi sebou mají koeficient 1 a jsou stejné, a celková aktiva byla vyřazena, protože vykazovala silnou korelaci s proměnnou log celková aktiva (koeficient korelace 0,768). Podobně byla vyřazena proměnná provozní náklady, protože vykazovala silnou korelaci s proměnnou tržby (koeficient korelace 0,926). Tato korelace by mohla vést ke zkreslení výsledků analýzy, proto byly tyto proměnné z výběru odebrány.

Proměnné s korelačním koeficientem 1 nebo -1 byly také vyloučeny, protože tato hodnota znamená, že jsou tyto proměnné zcela shodné. Nicméně jedná se dvou proměnných byla ponechána, protože byla statisticky významná. Podobně byl vybrán vlastní kapitál místo změny čistého jmění, které měly koeficient 1.

V další tabulce jsou uvedeny proměnné, které byly vybrány pro tvorbu modelu a jsou vypsány pouze ty proměnné, které byly významné podle t-testu.

Vybrané proměnné byly testovány na vzájemné vztahy mezi sebou a bylo zjištěno, že jejich korelační koeficient nepřesahuje 0,75 nebo -0,75, což je vyhovující.

Tabulka č. 21: Vybrané proměnné

Model	Proměnná
SME 2	pohledávky z obchodních vztahů / celková aktiva
	log celková aktiva
Lugovskaya	peněžní prostředky / krátkodobé závazky
	(peněžní prostředky+ krátkodobé pohledávky) / celková aktiva
	ROA
Conan & Holder	(oběžná aktiva-zásoby) / krátkodobé závazky
Slefendorfas	tržby
	EAT
	vlastní kapitál
	náklady z finančního majetku
Tereshchenko	Cash flow z provozní činnosti / krátkodobé závazky

3.2 Logistická regrese

Logistická regrese byla použita především proto, že dokáže dobře rozlišovat mezi bankrotními a nebankrotními firmami, což je klíčový cíl bankrotního modelu. Dále umožňuje testovat významnost jednotlivých proměnných, což umožňuje eliminovat ty, které nemají významný vliv na predikci bankrotu, a tím zlepšit celkovou výkonnost modelu. Výpočet modelu pomocí regresní analýzy byl proveden v programu IBM SPSS pomocí různých metod.

Model 1 - metoda dopředná s konstantou s použitím všech vybraných proměnných. Metoda dopředná v logistické regresi je jednou z metod postupného výběru proměnných pro vytvoření prediktivního modelu. V této metodě se nejdříve zvolí jedna proměnná, která nejvíce přispívá k vysvětlení závislé proměnné. Následně se postupně přidávají další proměnné, které zlepšují prediktivní schopnost modelu.

Model 2 – metoda dopředná bez konstanty s použitím všech vybraných proměnných.

Model 3 - metoda zpětná s konstantou s použitím všech vybraných proměnných. Metoda zpětná logistické regrese je alternativní metodou pro výběr nejvýznamnějších proměnných v logistické regresi. Na rozdíl od metody dopředné, kde postupně přidáváme proměnné do modelu, začínáme u plného modelu a postupně odstraňujeme proměnné, které nejsou signifikantní.

Model 4 - metoda zpětná bez konstanty s použitím pouze log celková aktiva, peněžní prostředky / krátkodobé závazky, (peněžní prostředky + krátkodobé pohledávky) / celková aktiva, ROA, (oběžná aktiva-zásoby) / krátkodobé závazky, EAT, tržby a vlastní kapitál. Zůstaly pouze proměnné, které jsou běžně uvedeny ve výkazech malých a středních podniků podle tabulky č.22.

Model 5 - metoda dopředná s konstantou s pouze log celková aktiva, peněžní prostředky / krátkodobé závazky, (peněžní prostředky + krátkodobé pohledávky) / celková aktiva, ROA, (oběžná aktiva-zásoby) / krátkodobé závazky, EAT, tržby a vlastní kapitál. Zůstaly pouze proměnné, které jsou běžně uvedeny ve výkazech malých a středních podniků tabulky č. 22.

V tabulce č. 22 je uveden počet platných pozorování z období t-1 z celkového počtu 497 podniků. V tabulce jsou vyznačeny proměnné s největším počtem pozorování. Proměnná Cash flow z provozní činnosti / krátkodobé závazky nebyla zahrnuta do výpočtu modelů 4 a 5, protože mikro a malé podniky často nemají k dispozici dostatek dat pro výpočet tohoto ukazatele. Namísto toho byly použity jiné ukazatele, které jsou běžně k dispozici pro mikro, malé a střední podniky jako například tržby, které jsou důležitým ukazatelem hospodářského výkonu podniku a zároveň jsou jednou z klíčových proměnných, které ovlivňují finanční výsledky podniku a jsou často snadno dostupnými údaji, protože jsou součástí povinných účetních výkazů podniků.

Tabulka č. 22: Počet platných pozorovaní podle proměnných

Model	Proměnná	Počet platných pozorování
SME 2	pohledávky z obchodních vztahů / celková aktiva	482
	log celková aktiva	495
Lugovskaya	peněžní prostředky / krátkodobé závazky	488
	(peněžní prostředky+ krátkodobé pohledávky) / celková aktiva	495
	ROA	492
Conan & Holder	(oběžná aktiva-zásoby) / krátkodobé závazky	494
Slefendorfas	tržby	466
	EAT	494
	vlastní kapitál	496
	náklady z finančního majetku	486
Tereshchenko	Cash flow z provozní činnosti / krátkodobé závazky	492

3.2.1 Model 1

Tato tabulka ukazuje výsledky logistické regrese modelu 1, která zkoumá vliv tří nezávislých proměnných: log celková aktiva, EAT a Cash flow z provozní činnosti/krátkodobé závazky a konstanty na binární výstup (aktivní/bankrot) v posledním kroku modelování. V tabulce jsou uvedeny hodnoty regresních koeficientů B pro každou proměnnou, spolu se Waldovou statistikou (Wald), stupněm volnosti (df) a statistickou významností (Sig.). Každá proměnná má různou míru vlivu na predikovaný výstup, přičemž nižší hodnota B indikuje menší vliv na predikci výstupu. Test Wald je test hypotézy o tom, zda je koeficient roven nule, což by znamenalo, že proměnná nemá významný vliv na predikci. Stupeň volnosti (df) udává počet pozorování mínus počet odhadovaných parametrů v modelu. Signifikance (Sig.) nebo p-hodnota udává pravděpodobnost, že daná proměnná je náhodná, což znamená, že nemá vliv na predikovaný výstup.

Tabulka č. 23: Výsledek krokové analýzy – model 1

(Zdroj: vlastní zpracování dle IBM SPSS)

Krok	Proměnné	B	Wald	df	Sig.
Krok 3	log celková aktiva	-6,567	49,210	1	0,000
	EAT	-0,0004	4,307	1	0,038
	Cash flow z provozní činnosti / krátkodobé závazky	-0,841	8,819	1	0,003
	Konstanta	23,821	44,084	1	0,000

Všechny proměnné jsou statisticky významné podle p-hodnoty na 5 % hladině významnosti.

Výraz pro výpočet pravděpodobnosti (p) v logistické regresi na základě modelu 1 je:

$$p = \frac{1}{1 + e^{-(23,821 - 6,567x_1 - 0,0004x_2 - 0,841x_3)}},$$

kde

X_1 = log celková aktiva

X_2 = EAT

X_3 = Cash flow z provozní činnosti / krátkodobé závazky

Cut off skoré modelu bylo odhadnuto následovně:

$p > 0,51$ vyhodnocen za bankrotní

$p < 0,51$ vyhodnocen za aktivní

3.2.2 Model 2

Tato tabulka ukazuje výsledky regrese modelu 2 pro 4 nezávislé proměnné: pohledávky z obchodních vztahů / celková aktiva, oběžná aktiva-zásoby / krátkodobé závazky, tržby a EAT v šestém kroku modelování.

Tabulka č. 24: Výsledek krokové analýzy – model 2

(Zdroj: vlastní zpracování dle IBM SPSS)

Krok	Proměnné	B	Wald	df	Sig.
Krok 6	pohledávky z obchodních vztahů / celková aktiva	5,136	8,438	1	0,004
	(oběžná aktiva-zásoby) / krátkodobé závazky	1,398	13,648	1	0,000
	tržby	-0,001	71,402	1	0,000
	EAT	0,0002	4,397	1	0,036

Všechny proměnné jsou statisticky významné podle p-hodnoty na 5 % hladině významnosti.

Výraz pro výpočet pravděpodobnosti (p) v logistické regresi na základě modelu 1 je:

$$p = \frac{1}{1 + e^{-(5,136x_{11} + 1,398x_{12} - 0,001x_{13} - 0,0002x_{14})}},$$

kde

X_{11} = pohledávky z obchodních vztahů / celková aktiva

X_{12} = (oběžná aktiva-zásoby) / krátkodobé závazky

X_{13} = tržby

X_{14} = EAT

Cut off skoré modelu bylo odhadnuto následovně:

$p > 0,115$ vyhodnocen za bankrotní

$p < 0,115$ vyhodnocen za aktivní

3.2.3 Model 3

Tato tabulka ukazuje výsledky logistické regrese modelu 3 pro tři nezávislé proměnné: log celková aktiva, ROA a Cash flow z provozní činnosti / krátkodobé závazky a konstantu v devátém kroku modelování.

Tabulka č. 25: Výsledek krokové analýzy – model 3

(Zdroj: vlastní zpracování dle IBM SPSS)

Krok	Proměnné	B	Wald	df	Sig.
Krok 9	log celková aktiva	-6,572	48,238	1	0,000
	ROA	-5,282	5,519	1	0,019
	Cash flow z provozní činnosti / krátkodobé závazky	-0,760	7,290	1	0,007
	Konstanta	23,773	43,005	1	0,000

Všechny proměnné jsou statisticky významné podle p-hodnoty na 5 % hladině významnosti.

Výraz pro výpočet pravděpodobnosti (p) v logistické regresi na základě modelu 1 je:

$$p = \frac{1}{1 + e^{-(23,773 - 6,572x_{21} - 5,282x_{22} - 0,760x_{23})}},$$

kde

X_{21} = log celková aktiva

X_{22} = ROA

X_{23} = Cash flow z provozní činnosti / krátkodobé závazky

Cut off skoré modelu bylo odhadnuto následovně:

$p > 0,433$ vyhodnocen za bankrotní

$p < 0,433$ vyhodnocen za aktivní

3.2.4 Model 4

Tato tabulka zobrazuje výsledky čtvrtého kroku modelování logistické regrese modelu 4, kde jsou použity pět nezávislých proměnných: peněžní prostředky/krátkodobé závazky, (peněžní prostředky + krátkodobé pohledávky) /celková aktiva, ROA a (oběžná aktiva-zásoby) / krátkodobé závazky, tržby.

Tabulka č. 26: Výsledek krokové analýzy – model 4

(Zdroj: vlastní zpracování dle IBM SPSS)

Krok	Proměnné	B	Wald	df	Sig.
Krok 4	peněžní prostředky / krátkodobé závazky	-0,609	5,791	1	0,016
	(peněžní prostředky+ krátkodobé pohledávky) / celková aktiva	4,324	10,594	1	0,001
	ROA	-2,505	4,362	1	0,037
	(oběžná aktiva-zásoby) / krátkodobé závazky	1,095	7,003	1	0,008
	tržby	-0,001	70,540	1	0,000

Všechny proměnné jsou statisticky významné podle p-hodnoty na 5 % hladině významnosti.

Výraz pro výpočet pravděpodobnosti (p) v logistické regresi na základě modelu 1 je:

$$p = \frac{1}{1 + e^{(-0,609x_{31} + 4,324x_{32} - 2,505x_{33} + 1,095x_{34} - 0,001x_{35})}},$$

kde

X_{31} = peněžní prostředky / krátkodobé závazky

X_{32} = (peněžní prostředky+ krátkodobé pohledávky) / celková aktiva

X_{33} = výsledek hospodaření po zdanění / celková aktiva

X_{34} = (oběžná aktiva-zásoby) / krátkodobé závazky

X_{35} = tržby

Cut off skoré modelu bylo odhadnuto následovně:

$p > 0,357$ vyhodnocen za bankrotní

$p < 0,357$ vyhodnocen za aktivní

3.2.5 Model 5

Tato tabulka zobrazuje výsledky logistické regrese modelu 5 a čtyři nezávislé proměnné v posledním kroku modelování.

Tabulka č. 27: Výsledek krokové analýzy – model 5

(Zdroj: vlastní zpracování dle IBM SPSS)

Krok	Proměnné	B	Wald	df	Sig.
Krok 6	(peněžní prostředky+ krátkodobé pohledávky) / celková aktiva	2,617	8,187	1	0,004
	(oběžná aktiva-zásoby) / krátkodobé závazky	1,473	14,255	1	0,000
	tržby	-0,001	77,938	1	0,000
	EAT	0,0002	4,945	1	0,026

Všechny proměnné jsou statisticky významné podle p-hodnoty na 5 % hladině významnosti.

Výraz pro výpočet pravděpodobnosti (p) v logistické regresi na základě modelu 1 je:

$$p = \frac{1}{1 + e^{-(2,617x_{41} + 1,473x_{42} - 0,001x_{43} + 0,0002x_{44})}},$$

kde

X_{41} = (peněžní prostředky+ krátkodobé pohledávky) / celková aktiva

X_{42} = (oběžná aktiva-zásoby) / krátkodobé závazky

X_{43} = tržby

X_{44} = výsledek hospodaření po zdanění/ celková aktiva

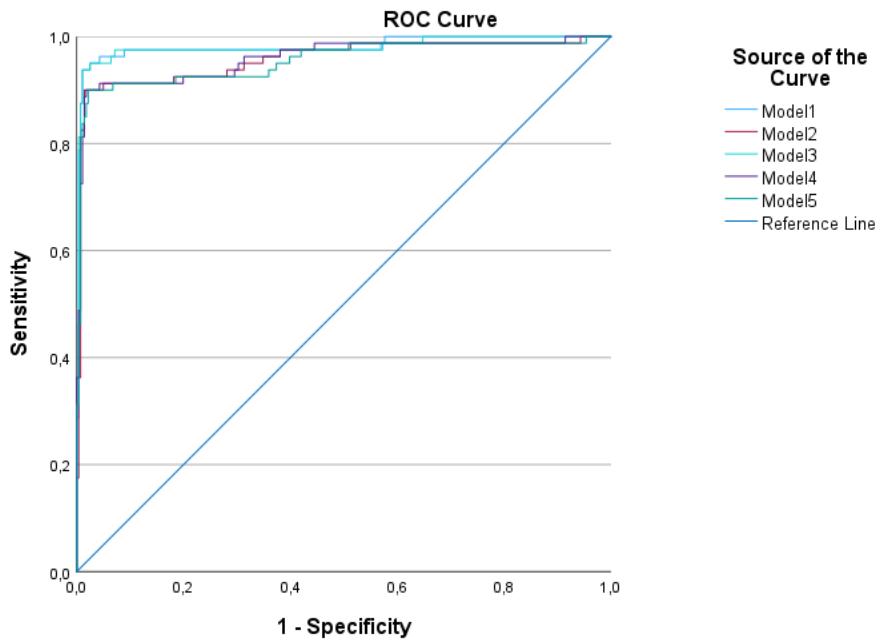
Cut off skoré modelu bylo odhadnuto následovně:

$p > 0,338$ vyhodnocen za bankrotní

$p < 0,338$ vyhodnocen za aktivní

3.3 ROC křivka sestavených modelů na trénovacích vzorcích

ROC křivka byla spočítána na základě hodnot trénovacích vzorků (cca 70 % od celkového množství vybraných podniků). Podle grafu máme výsledky analýzy křivky ROC pro pět různých modelů.



Graf č. 10: ROC křivka – modely 1,2,3,4,5

(Zdroj: vlastní zpracování dle IBM SPSS)

Výsledky ukazují, že modely 1 a 3 vykazují vysokou schopnost rozlišovat mezi pozitivními a negativními případy, což je patrné z vysoké hodnoty AUC. Na druhou stranu, modely 2, 4 a 5 mají nižší AUC hodnoty, což naznačuje menší schopnost rozlišování. Nicméně všechny modely jsou statisticky významné.

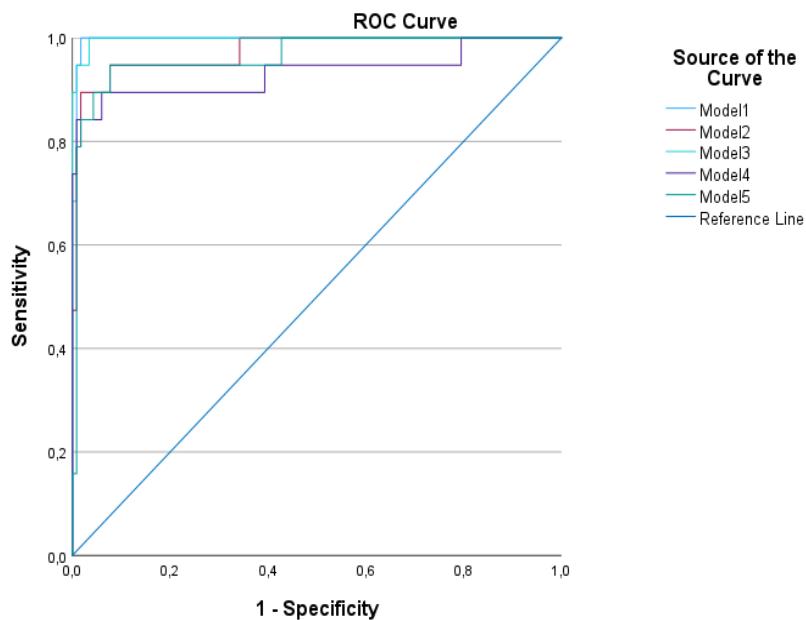
Tabulka č. 28: Plocha pod ROC křivkou – model 1, 2,3,4,5

(Zdroj: vlastní zpracování dle IBM SPSS)

Model	Plocha pod křivkou	p-hodnota	95% interval spolehlivosti	
			Spodní hranice	Horní hranice
Model 1	0,981	0,000	0,960	1,000
Model 2	0,957	0,000	0,926	0,988
Model 3	0,980	0,000	0,958	1,000
Model 4	0,959	0,000	0,930	0,989
Model 5	0,955	0,000	0,922	0,987

3.4 ROC křivka sestavených modelů na testovacích vzorcích

ROC křivka byla spočítána na základě hodnot testovacích vzorků (cca 30 % od celkového množství vybraných podniků). Podle grafu máme výsledky analýzy křivky ROC pro pět různých modelů.



Graf č. 11: ROC křivka – modely 1,2,3,4,5

(Zdroj: vlastní zpracování dle IBM SPSS)

Výsledky ukazují, že modely 1, 3 mají vysokou AUC hodnotu, což znamená, že jsou velmi schopné rozlišovat mezi pozitivními a negativními případy. Na druhé straně, modely 2, 4 a 5 mají nižší AUC hodnoty, což znamená, že jsou méně schopné rozlišovat mezi pozitivními a negativními případy. Všechny modely jsou statisticky významné.

Tabulka č. 29: Plocha pod ROC křivkou – model 1, 2,3,4,5

(Zdroj: vlastní zpracování dle IBM SPSS)

Model	Plocha pod křivkou	p-hodnota	95% interval spolehlivosti	
			Spodní hranice	Horní hranice
Model 1	0,997	0,000	0,991	1,000
Model 2	0,973	0,000	0,937	1,000
Model 3	0,998	0,000	0,993	1,000
Model 4	0,933	0,000	0,846	1,000
Model 5	0,965	0,000	0,920	1,000

3.5 Přesnost sestavených modelů na základě trénovacích vzorků

Data trénovacích vzorků tvoří přibližně 70 % celkového množství vybraných malých a středních podniků.

Tabulka č. 30: Srovnání přesnosti sestavených modelů na základě trénovacích vzorků

Přesnost		Model 1	Model 2	Model 3	Model 4	Model 5
Správně klasifikované podniky	aktivní	absolutně	278	267	278	277
		relativně, %	99	95	99	99
	bankrotní	absolutně	73	73	73	67
		relativně, %	91	91	91	84
Špatně klasifikované podniky	aktivní	absolutně	3	14	3	4
		relativně, %	1	5	1	1
	bankrotní	absolutně	7	7	7	13
		relativně, %	9	9	9	16
Celková, %		95,1	91,2	91,8	91,2	91,8
Podle AUC, %		98,0	95,9	95,5	95,9	95,5

Tato tabulka prezentuje výsledky klasifikace podniků pomocí pěti různých modelů. Model 1 a Model 3 dosáhly nejvyšší přesnosti u správně klasifikovaných aktivních podniků, kde dosáhly 95-98 % úspěšnosti. Podle hodnoty AUC Model 1 dosáhl nejvyšší hodnoty AUC s 98,1 %, zatímco model 5 měl nejnižší hodnotu AUC s 95,5 %.

3.6 Přesnost sestavených modelů na základě testovacích vzorků

Data trénovacích vzorků tvoří přibližně 30 % celkového množství vybraných malých a středních podniků. Tabulka prezentuje výsledky přesnosti klasifikace pro pět různých modelů.

Tabulka č. 31: Srovnání přesnosti sestavených modelů na základě testovacích vzorků

Přesnost		Model 1	Model 2	Model 3	Model 4	Model 5
Správně klasifikované podniky	aktivní	absolutně	116	114	115	116
		relativně, %	99	97	98	99
	bankrotní	absolutně	18	17	18	14
		relativně, %	100	89	95	74
Špatně klasifikované podniky	aktivní	absolutně	1	3	2	1
		relativně, %	1	3	2	1
	bankrotní	absolutně	0	2	1	5
		relativně, %	0	11	5	26
Celková, %		99,6	93,5	96,5	86,4	88,6
Podle AUC, %		99,7	97,3	99,8	93,3	96,5

Z výsledků lze vidět, že většina modelů měla vysokou absolutní a relativní přesnost klasifikace pro aktivní podniky, zatímco u bankrotních podniků byly výsledky nižší. Celkově vzato, všechny modely dosáhly vysoké celkové přesnosti klasifikace, ale nejvyšší přesnost měly Model 1 a 3 s přesností 96,5-99 %. Mezi proměnné, které mají významný vliv na predikce bankrotu podniku patří: log celková aktiva, EAT, Cash flow z provozní činnosti / krátkodobé závazky a ROA.

4 SROVNÁNÍ EFEKTIVNOSTI VYTVOŘENÉHO MODELU A VYBRANÝCH MODELŮ

V předchozí kapitole bylo vytvořeno celkem 5 bankrotních predikčních modelů s přesností klasifikace přes 90 %, což svědčí o jejich vysoké výkonnosti. Z těchto modelů byl vybrán model 1 jako nejlepší, protože prokázal nejvyšší spolehlivost jak pro trénovací, tak pro testovací vzorky. Přesnost tohoto modelu dosahuje kolem 99 %. Model 1 se skládá z tří proměnných a konstanty. Tyto tři proměnné jsou log celková aktiva, EAT a Cash flow z provozní činnosti / krátkodobé závazky.

V této kapitole budou porovnávány výsledky modelu 1 s výsledky dalších vybraných modelů, jako jsou například SME 2, Lugovskaya, Conan & Holder, Gediminas Šlefendorfas a Tereshchenko. Pro srovnání byla použita data za období t-1, tedy rok před bankrotom.

Přesnost modelu SME 2 v období t-1 dosáhla hodnoty 75 %, což odpovídá stanovené přesnosti autory. Přesnost modelu Lugovskaya je kolem 63 %, zatímco přesnost modelu Conan & Holder dosahuje pouze 56 %. Naopak přesnost modelu Gediminas Šlefendorfas je relativně vysoká a stanovena na úrovni 89 %. Přesnost modelu Tereshchenko dosahuje stejné hodnoty jako model SME 2, tedy 74 %.

Tabulka č. 33 zobrazuje srovnání přesnosti klasifikace bankrotních a aktivních podniků pro různé modely.

Tabulka č. 32: Srovnání přesnosti nového modelu 1 s vybranými modely

Model	Model 1 trénovací	Model 1 testovací	SME 2	Lugovskaya	Conan & Holder	Gediminas Šlefendorfas	Tereshchenko
Aktivní	99 %	99 %	80 %	80 %	78 %	99 %	71 %
Bankrotní	91 %	100 %	70 %	46 %	33 %	72 %	77 %
Celkem	95 %	99 %	75 %	63 %	56 %	85 %	74 %

Celkově model 1 dosahuje nejvyšší přesnosti klasifikace v porovnání s ostatními modely.

ZÁVĚR

Cílem práce bylo zhodnotit přesnost pěti vybraných bankrotních modelů a její porovnání s původně deklarovanou přesností. A následně vhodnou metodou odvodit vlastní predikční model určený pro malé a střední podniky a testovat přesnost tohoto modelu.

Teoretická část diplomové práce se zabývala definování klíčových pojmy spojených s predikcí bankrotu, tvorbou a testováním modelů. Kromě toho se v této části práce také rozebíraly teoretické příčiny bankrotu a jeho právní regulace, dále byly popsány různé metody predikce bankrotu a vysvětleny základní kroky tvorby a testování prediktivních modelů. Tato část práce byla podložena relevantními zdroji a výzkumy v oblasti predikce bankrotu a tvorby modelů.

V praktické části práce bylo provedeno vypočítání a zhodnocení přesnosti pěti různých modelů na vlastním datovém vzorku z Orbisu, který zahrnoval malé a střední podniky zpracovatelského průmyslu z České a Slovenské republiky. Přesnost byla hodnocena na základě ROC křivky a plochy pod křivkou, které byly sestaveny v statistickém programu IBM SPSS. Nejpřesnější model podle hodnocení byl model Gediminas Šlefendorfas za období rok před bankrotem, méně přesnějšími se ukázaly model SME 2 s 75 % přesnosti, model Tereshchenko měl 74 % přesnosti a model Lugovskaya s přesností 63 %. Nejhorších výsledků dosáhl model Conan & Holder – 56 % přesnosti. Kromě hodnocení přesnosti byla také provedena analýza významnosti jednotlivých proměnných pomocí T-testů pro jednotlivé modely pomocí programu IBM SPSS. Pomoci korelační analýzy byla řešena multikolinearity proměnných pro následné odvození do tvorby nového modelu.

Analytická část diplomové práce byla věnovaná tvorbě vlastního bankrotního modelu. Vzorek byl použit stejný, jaký byl při zhodnocení přesnosti vybraných modelů, ale byl rozdělen na dvě skupiny: trénovací a testovací. Logistická regrese byla vybraná pro tvorbu modelu z důvodů její vysoké prediktivní schopnosti, jednoduché použitelnosti a snadné interpretace výsledků. Před zařazením proměnných do modelu byla provedena korelační analýza, aby byly vyřazeny proměnné s vysokou korelací mezi sebou a minimalizován vliv multikolinearity na výsledky modelu. Následně byly pomocí t-testů vybrány pouze statisticky významné proměnné pro zařazení do modelu.

Pět bankrotních modelů byly vytvořeny na základě 70 % dat z celkového počtu vzorků, které byly určeny jako trénovací vzorky pomocí regresní analýzy. Tyto modely se lišily v

proměnných a metodách použitých při jejich vytváření. Všechny modely prokázaly vysokou spolehlivost, přes 90 %. Nejvyšší přesnost, 99 %, dosáhly modely 1 a 3 na testovacích vzorcích, hodnocené pomocí ROC křivky a plochy pod ní. Model 1 byl sestaven pomocí metody dopředné s konstantou a zahrnoval proměnné logaritmus celková aktiva, zisk po zdanění a Cash flow z provozní činnosti / krátkodobé závazky. Naopak model 3 byl vytvořen metodou zpětnou s konstantou a obsahoval proměnné logaritmus celková aktiva, rentabilita aktiv a Cash flow z provozní činnosti / krátkodobé závazky. Největší vliv na predikci bankrotu měly proměnné, které se vyskytovaly v obou modelech, konkrétně logaritmus celková aktiva a Cash flow z provozní činnosti / krátkodobé závazky. Oba nejlepší modely používají logaritmus celkových aktiv, což může naznačovat, že velikost aktiv je důležitým faktorem při predikci bankrotu. Stejně tak, využití Cash flow z provozní činnosti / krátkodobé závazky jako proměnné také naznačuje, že likvidita podniku je důležitá při predikci jeho bankrotu.

Na poslední etapě srovnání nově vytvořeného modelu 1 s bankrotními modely jiných autorů lze posoudit, že tento nový model dosahuje nejvyšší přesnosti oproti ostatním. Je nutné však poznamenat, že pro jeho vytvoření byl použit relativně malý vzorek dat, který zahrnoval pouze české a slovenské podniky, a tudíž je možné, že v případě změny velikosti vzorku nebo země se přesnost modelu může lišit.

SEZNAM POUŽITÝCH ZDROJŮ

1. Metodika pro psaní bakalářských a diplomových prací na Národohospodářské fakultě Vysoké školy ekonomické v Praze [online]. In: . 2013, s. 30 [cit. 2023-05-08]. Dostupné z: <https://nf.vse.cz/wp-content/uploads/page/1069/Metodika-pro-psani%CC%81-BP-a-DP-29-9-2014-12.pdf>
2. KRATOCHVÍLOVÁ, Hana. Zrušení firem: likvidace a úpadek. Praha: C. H. Beck, 2002, xiii, 175 s. ISBN 80-7179-675-1.
3. Zákon č. 182/2006 Sb.: Zákon o úpadku a způsobech jeho řešení (insolvenční zákon) [online]. In: . [cit. 2023-02-08]. Dostupné z: <https://www.zakonyprolidi.cz/cs/2006-182>
4. HORVÁTHOVÁ, Jarmila, Martina MOKRIŠOVÁ a Igor PETRUŠKA. Selected Methods of Predicting Financial Health of Companies: Neural Networks Versus Discriminant Analysis. Information [online]. 2021, 12(12) [cit. 2023-02-08]. ISSN 2078-2489. Dostupné z: doi:10.3390/info12120505
5. PLATT, H.D. a M. PLATT. Comparing Financial Distress and Bankruptcy [online]. 2006, 27 [cit. 2023-02-08]. Dostupné z: <https://ssrn.com/abstract=876470>
6. ALTMAN, Edward I. Company Bankruptcy in America. D. C. Health and Company. Lexington, 1971. ISBN 978-0669753097.
7. TOMAS, Ivana a Mira DIMITRIC. Micro And Macroeconomic Variables In Predicting Financial Distress Of Companies [online]. Split: Sveuciliste u Splitu, 2011, 781-802 [cit. 2023-02-08]. ISSN 18474497. Dostupné z: <https://www.proquest.com/conference-papers-proceedings/micro-macroeconomic-variables-predicting/docview/1284742024/se-2>
8. ACHIM, Monica Violeta a Sorin Nicolae BORLEA. Considerations on business risk of bankruptcy. Review of Economic Studies and Research Virgil Madgearu [online]. 2012, (vol. 5, 2), 5-29 [cit. 2023-03-02]. ISSN 20690606. Dostupné z: <https://www.proquest.com/docview/1319809179/fulltextPDF/83B03C0621694B16PQ/1?accountid=17115>
9. YOUSAF, Muhammad a Petr BRIS. Assessment of bankruptcy risks in Czech companies using regression analysis. Problems and Perspectives in Management [online]. 2021, (vol. 19, 3), 46-55 [cit. 2023-03-02]. ISSN 17277051. Dostupné z:

[https://www.proquest.com/docview/2628315348/BDC83D539A684ADBPQ/1?acco untid=17115](https://www.proquest.com/docview/2628315348/BDC83D539A684ADBPQ/1?accoun tid=17115)

10. The economic essence of the concept of “bankruptcy”: causes, and consequences for the enterprise [online]. Infrastruktura rynku. Odesa, 2018 [cit. 2023-03-02]. ISBN 2519-2868. Dostupné z: [http://market- infr.od.ua/journals/2018/18_2018_ukr/18_2018.pdf](http://market-infr.od.ua/journals/2018/18_2018_ukr/18_2018.pdf)
11. NICULESCU, M. Global strategic diagnostic. Publishing House Economica. Bucuresti, 1997, str. 414.
12. Zákon č. 40/2009 Sb.: Zákon trestní zákoník [online]. In: . [cit. 2023-03-02]. Dostupné z: <https://www.zakonyprolidi.cz/cs/2009-40>
13. LANDA, Martin. Ekonomika insolvenčního řízení. Ostrava: Key Publishing, 2009. Ekonomie (Key Publishing). ISBN 978-80-7418-031-6.
14. CARTER, Richard a Howard Van AUKEN. Small Firm Bankruptcy. Journal of Small Business Management [online]. 2006, 44(4), 493-512 [cit. 2023-03-02]. ISSN 0047-2778. Dostupné z: doi:10.1111/j.1540-627X.2006.00187.x
15. Zákon č. 563/1991 Sb.: Zákon o účetnictví [online]. In: . [cit. 2023-03-15]. Dostupné z: <https://www.zakonyprolidi.cz/cs/1991-563>
16. Zákon č. 89/2012 Sb.: Zákon občanský zákoník [online]. In: . [cit. 2023-03-15]. Dostupné z: <https://www.zakonyprolidi.cz/cs/2012-89>
17. Zákon č. 90/2012 Sb.: Zákon o obchodních společnostech a družstvech (zákon o obchodních korporacích) [online]. In: . [cit. 2023-03-15]. Dostupné z: <https://www.zakonyprolidi.cz/cs/2012-90>
18. Vyhláška č. 190/2017 Sb.: Vyhláška k provedení § 3 odst. 3 insolvenčního zákona (vyhláška o platební neschopnosti podnikatele) [online]. In: . [cit. 2023-03-15]. Dostupné z: <https://www.zakonyprolidi.cz/cs/2017-190>
19. SME definition [online]. [cit. 2023-03-15]. Dostupné z: https://single-market-economy.ec.europa.eu/smes/sme-definition_en
20. Commission Recommendation of 6 May 2003 concerning the definition of micro, small and medium-sized enterprises [online]. 2003 [cit. 2023-03-15]. Dostupné z: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32003H0361>
21. PASEKOVÁ, Marie, Zuzana CRHOVÁ a Eva KUDEROVÁ. Pohledávky po splatnosti u malých a středních podniků v České republice. Trendy Ekonomiky a

- Managementu [online]. 2014, (vol. 8, 20), 47-57 [cit. 2023-03-28]. ISSN 18028527.
Dostupné z:
<https://www.proquest.com/docview/1625397174/285C1F6E7AFC4461PQ/1?accountid=17115>
22. Český statistický úřad (ČSÚ) [online]. [cit. 2023-03-28]. Dostupné z:
<https://www.czso.cz/>
23. C – Zpracovatelský průmysl [online]. [cit. 2023-03-28]. Dostupné z:
<http://www.nace.cz/C-zpracovatelsky-prumysl>
24. HORVÁTHOVÁ, Jarmila a Martina MOKRIŠOVÁ. Comparison of the Results of a Data Envelopment Analysis Model and Logit Model in Assessing Business Financial Health [online]. Information, 2020, (vol. 11, 3), 160 [cit. 2023-03-28]. Dostupné z:
<https://www.proquest.com/docview/2380484394/4273455AF1774EA8PQ/1?accountid=17115>
25. WU, Y., GAUNT, C., GRAY, S. A comparison of alternative bankruptcy prediction models. Journal of Contemporary Accounting & Economics. 2010, vol. 6, pp. 34-45. ISSN 1815-5669
26. JAMES, Gareth, Daniela WITTEN, Trevor HASTIE a Robert TIBSHIRANI. An Introduction to Statistical Learning [online]. In: . 2013 [cit. 2023-03-28]. Dostupné z: doi:10.1007/978-1-4614-7138-7
27. ALTMAN, Edward I, Małgorzata IWANICZ-DROZDOWSKA, Erkki K LAITINEN a Arto. Distressed Firm and Bankruptcy Prediction in an International Context: A Review and Empirical Analysis of Altman's Z-Score Model [online]. 2014, 47 [cit. 2023-03-28]. Dostupné z:
https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2536340
28. Politická ekonomie [online]. 58. 2010 [cit. 2023-03-28]. ISSN 00323233. Dostupné z: <http://polek.vse.cz/doi/10.18267/j.polek.754.html>
29. DLUHOŠOVÁ, Markéta. Stanovení pravděpodobnosti defaultu klientů pomocí scóringového modelu [online]. Ostrava, 2016 [cit. 2023-03-28]. Dostupné z:
<http://hdl.handle.net/10084/113556>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.

30. 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, no. 2, s. 151-166. ISSN 1573-7179
31. GASTWIRTH, Joseph L., Yulia R. GEL a Weiwen MIAO. The Impact of Levene's Test of Equality of Variances on Statistical Theory and Practice. *Statistical Science* [online]. 2009, 24(3) [cit. 2023-03-28]. ISSN 0883-4237. Dostupné z: doi:10.1214/09-STS301
32. ŘEHÁK, Jan a Ondřej BROM. SPSS - Praktická analýza dat. Brno: Computer Press, 2015, 336 stran : ilustrace (některé barevné). ISBN 978-80-251-4609-5.
33. FAWCETT, Tom. An introduction to ROC analysis. *Pattern Recognition Letters* [online]. 2006, 27(8), 861-874 [cit. 2023-03-29]. ISSN 01678655. Dostupné z: doi:10.1016/j.patrec.2005.10.010
34. SLAVÍČEK, Ondřej a Michal KUBĚNKA. Bankruptcy prediction models based on the logistic regression for companies in the Czech Republic [online]. Ostrava, 2016, 924-931 [cit. 2023-03-29]. Dostupné z: <http://hdl.handle.net/10195/67220>
35. VALASKOVA, Katarina, Tomas KLIESTIK, Lucia SVABOVA a Peter ADAMKO. Financial Risk Measurement and Prediction Modelling for Sustainable Development of Business Entities Using Regression Analysis. *Sustainability* [online]. 2018, 10(7) [cit. 2023-03-29]. ISSN 2071-1050. Dostupné z: doi:10.3390/su10072144
36. ALTMAN, E. I. and G. SABATO. Modelling Credit Risk for SMEs: Evidence from the U.S. Market. *Abacus*. 2007, vol. 43, no. 3, s. 332-357. ISSN 0001-3072
37. SLAVÍČEK, Ondřej a Michal KUBĚNKA. Relationship between level of prosperity and failure prediction [online]. Ostrava, 2016, 505-512 [cit. 2023-03-29]. Dostupné z: <http://hdl.handle.net/10195/67289>
38. KUBĚNKA, Michal, Jan ČAPEK a František SEJKORA. A NEW LOOK AT BANKRUPTCY MODELS. *E M Ekonomie a Management* [online]. 2021, 24(3), 167-185 [cit. 2023-03-29]. ISSN 12123609. Dostupné z: doi:10.15240/tul/001/2021-3-010
39. ALTMAN, Edward I., Gabriele SABATO a Nick WILSON. The Value of Non-Financial Information in SME Risk Management [online]. 2008, 40 [cit. 2023-01-29]. Dostupné z: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1320612

40. LUGOVSKAYA, Lyudmila. Predicting default of Russian SMEs on the basis of financial and non-financial variables. *Journal of Financial Services Marketing* [online]. 2010, 14(4), 301-313 [cit. 2023-01-29]. ISSN 1363-0539. Dostupné z: doi:10.1057/fsm.2009.28
41. IVASCU, Elena Valentina a Nicoleta BARBUTA MISU. Influences of the Capital Structure and the Cost of Capital on Financial Performance. Case Study on ENGIE Group. *Journal of Financial Services Marketing* [online]. 2010, 2017-11-15, 14(4), 304-320 [cit. 2023-01-29]. ISSN 1363-0539. Dostupné z: doi:10.18662/lumproc.rce2017.1.26
42. ŠLEFENDORFAS, Gediminas. Bankruptcy prediction model for private limited companies of Lithuania. *Ekonomika*. 2016, 95(1), 134-152. ISSN 2424-6166. Dostupné z: doi:10.15388/Ekon.2016.1.9910
43. NIKOLOV, Oleksandr. Analysis of probability of the enterprise bankruptcy. *Scientific Bulletin of the Odessa National Economic University* [online]. 2021, 9-10(286-287), 112-118 [cit. 2023-01-29]. ISSN 24099260. Dostupné z: doi:10.32680/2409-9260-2021-9-10-286-287-112-118

SEZNAM POUŽITÝCH ZKRATEK

SME	Malé a střední podniky
CZ NACE	Česká nomenklatura ekonomických činností
HDP	Hrubý domácí produkt
ČSÚ	Český statistický úřad
NYSE	Akciová burza v New Yorku ve Spojených státech amerických
ROC	Receiver Operating Characteristic
AUC	Area Under Curve / plocha pod křivkou
ROA	Rentabilita aktiv
EAT	Zisk po zdanění
ROS	Rentabilita tržeb

SEZNAM POUŽITÝCH OBRÁZKŮ

Obrázek č. 1: Matrice záměn	38
Obrázek č. 2: Základní ROC graf	40

SEZNAM POUŽITÝCH TABULEK

Tabulka č. 1 Počet zaniklých podniků za rok 2017-2019 dle ekonomické činnosti	24
Tabulka č. 2: Počet vzniklých podniků za rok 2017-2019 dle ekonomické činnosti.....	25
Tabulka č. 3: Riziko bankrotu podniku	46
Tabulka č. 4: Přesnost testování aktivních a bankrotních podniků při modelu SME 2...	51
Tabulka č. 5: Přesnost testování aktivních a bankrotních podniků při modelu Lugovskaya	52
Tabulka č. 6: Přesnost testování aktivních a bankrotních podniků při modelu Conan & Holder	53
Tabulka č. 7: Přesnost testování aktivních a bankrotních podniků při modelu Gediminas Šlefendorfas	53
Tabulka č. 8: Přesnost testování aktivních a bankrotních podniků při modelu Tereshchenko	54
Tabulka č. 9: Plocha pod ROC křivkou – model SME 2.....	56
Tabulka č. 10: Plocha pod ROC křivkou – model Lugovskaya.....	57
Tabulka č. 11: Plocha pod ROC křivkou – model Conan & Holder	58
Tabulka č. 12: Plocha pod ROC křivkou – model Gediminas Šlefendorfas	59
Tabulka č. 13: Plocha pod ROC křivkou – model Tereshchenko	60
Tabulka č. 14: T-test – model SME 2	62
Tabulka č. 15: T-test – model Lugovskaya	63
Tabulka č. 16: T-test – model Conan & Holder	63
Tabulka č. 17: T-test – model Gediminas Šlefendorfas	64
Tabulka č. 18: T-test – model Tereshchenko.....	64
Tabulka č. 19: Seznam testovaných proměnných	66
Tabulka č. 20: Seznam vybraných proměnných	67
Tabulka č. 21: Vybrané proměnné	68
Tabulka č. 22: Počet platných pozorovaní podle proměnných	70
Tabulka č. 23: Výsledek krokové analýzy – model 1	71
Tabulka č. 24: Výsledek krokové analýzy – model 2	72
Tabulka č. 25: Výsledek krokové analýzy – model 3	73
Tabulka č. 26: Výsledek krokové analýzy – model 4.....	74
Tabulka č. 27: Výsledek krokové analýzy – model 5.....	75

Tabulka č. 28: Plocha pod ROC křivkou – model 1, 2,3,4,5	76
Tabulka č. 29: Plocha pod ROC křivkou – model 1, 2,3,4,5	77
Tabulka č. 30: Srovnání přesnosti sestavených modelů na základě trénovacích vzorků	78
Tabulka č. 31: Srovnání přesnosti sestavených modelů na základě testovacích vzorků .	78
Tabulka č. 32: Srovnání přesnosti nového modelu 1 s vybranými modely.....	80

SEZNAM POUŽITÝCH GRAFŮ

Graf č. 1: Počet zaniklých podniků za rok 2017-2019 dle ekonomické činnosti	24
Graf č. 2: Počet vzniklých podniků za rok 2017-2019 dle ekonomické činnosti	25
Graf č. 3: Počet podniků za rok 2020 dle ekonomické činnosti	27
Graf č. 4: Podíl odvětví podle CZ-NACE dle obratu (mil. CZK).....	27
Graf č. 5: ROC křivka – model SME 2	55
Graf č. 6: ROC křivka – model Lugovskaya	56
Graf č. 7: ROC křivka – model Conan & Holder	57
Graf č. 8: ROC křivka – model Gediminas Šlefendorfas.....	59
Graf č. 9: ROC křivka – model Tereshchenko.....	60
Graf č. 10: ROC křivka – modely 1,2,3,4,5	76
Graf č. 11: ROC křivka – modely 1,2,3,4,5	77