

Univerzita Pardubice

Fakulta ekonomicko-správní

**Diskriminační analýza a její využití pro posouzení finančního zdraví
podniku**

Bc. Michal Votava

**Diplomová práce
2017**

Univerzita Pardubice
Fakulta ekonomicko-správní
Akademický rok: 2016/2017

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Michal Votava**
Osobní číslo: **E15753**
Studijní program: **N6208 Ekonomika a management**
Studijní obor: **Ekonomika a management podniku**
Název tématu: **Diskriminační analýza a její využití pro posouzení finančního zdraví podniku**
Zadávací katedra: **Ústav matematiky a kvantitativních metod**

Z á s a d y p r o v y p r a c o v á n í :


Cílem práce je popsat funkci diskriminační analýzy jako takové a ukázat aplikaci této metody při posuzování finančního zdraví podniku.

Osnova:

- Charakteristika diskriminační analýzy.
- Zpracování a analýza účetních dat.
- Aplikace metody pro posouzení finančního zdraví podniku.
- Vyhodnocení a diskuze výsledků.

Rozsah grafických prací: –
Rozsah pracovní zprávy: cca 50 stran
Forma zpracování diplomové práce: tištěná/elektronická
Seznam odborné literatury:

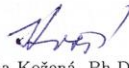
BLAHA, Zdeněk a Irena JINDŘICHOVSKÁ. Jak posoudit finanční zdraví firmy. 3., rozš. vyd. Praha: Management Press, 2006. ISBN 80-7261-145-3.
HEBÁK, Petr, Jiří HUSTOPECKÝ, Eva JAROŠOVÁ a Ivana MALÁ. Vícerozměrné statistické metody. Praha: Informatorium, 2005. ISBN 80-7333-025-3.
KNÁPKOVÁ, Adriana, Drahomíra PAVELKOVÁ a Karel ŠTEKER. Finanční analýza: komplexní průvodce s příklady. 2., rozš. vyd. Praha: Grada, 2013. Prosperita firmy. ISBN 978-80-247-4456-8.
STANKOVIČOVÁ, Iveta a Mária VOJTKOVÁ. Viacrozmerné štatistické metódy s aplikáciami. Bratislava: Iura Edition, 2007. Edícia Ekonómia. ISBN 978-80-8078-152-1.
VOCHOZKA, Marek. Metody komplexního hodnocení podniku. Praha: Grada, 2011. Finanční řízení. ISBN 978-80-247-3647-1.

Vedoucí diplomové práce: 
Mgr. David Zapletal, Ph.D.
Ústav matematiky a kvantitativních metod

Datum zadání diplomové práce: 4. září 2016
Termín odevzdání diplomové práce: 28. dubna 2017


doc. Ing. Romana Provazníková, Ph.D.
děkanka

L.S.


doc. Ing. Marcela Kožená, Ph.D.
vedoucí ústavu

V Pardubicích dne 4. září 2016

Prohlašuji:

Tuto práci jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorský zákon, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 9/2012, bude práce zveřejněna v Univerzitní knihovně a prostřednictvím Digitální knihovny Univerzity Pardubice

V Pardubicích dne 26. června 2017

Bc. Michal Votava

PODĚKOVÁNÍ

Rád bych touto cestou poděkoval vedoucímu diplomové práce Mgr. Davidu Zapletalovi, Ph. D., za velmi cenné rady, odborné vedení a obohacující konzultace.

ANOTACE

Práce je věnována diskriminační analýze a jejímu využití v oblasti analýzy finančního zdraví podniku. Na základě diskriminační analýzy byl vytvořen bankrotní model predikující úpadek podniku z oblasti zpracovatelského průmyslu v České republice.

KLÍČOVÁ SLOVA

diskriminační analýza, predikce bankrotu, finanční zdraví, úpadek podniku

TITLE

Discriminant Analysis and its Application as an Evaluation Tool for Company's Financial Health

ANNOTATION

The work is dedicated to the discriminant analysis and its use in company's financial health analysis. Based on the discriminant analysis, bankruptcy model was created to predict bankruptcy of manufacturing companies in Czech Republic.

KEYWORDS

discriminant analysis, bankruptcy prediction, financial health, bankruptcy

OBSAH

ÚVOD	10
1 DISKRIMINAČNÍ ANALÝZA	11
1.1 PŘEDPOKLADY POUŽITÍ DISKRIMINAČNÍ ANALÝZY	11
1.2 POPISNÁ ÚLOHA DISKRIMINAČNÍ ÚLOHY	12
1.2.1 Kanonická diskriminační analýza	13
1.2.2 Kroková diskriminační analýza	15
1.3 KLASIFIKAČNÍ ÚLOHA DISKRIMINAČNÍ ANALÝZY	15
1.3.1 Ověření přesnosti klasifikace	18
2 VYBRANÉ MODELY PRO POSOUZENÍ FINANČNÍHO ZDRAVÍ	20
2.1.1 Altmanovo Z-skóre	21
2.1.2 Beermanova diskriminační funkce	23
2.1.3 Tafflerův index	24
2.1.4 Indexy IN	25
2.1.5 Další vybrané modely	28
3 VÝBĚR DAT PRO DISKRIMINAČNÍ ANALÝZU	30
3.1 ROZLIŠENÍ BONITNÍCH A BANKROTNÍCH PODNIKŮ	30
3.2 VÝBĚR PROMĚNNÝCH	31
3.3 VÝBĚR VZORKU PODNIKŮ	33
4 TVORBA MODELU	38
4.1 VÝBĚR PROMĚNNÝCH	38
4.2 VÝSLEDNÝ MODEL A JEHO KOEFICIENTY	43
4.3 TESTOVÁNÍ ÚSPĚŠNOSTI MODELU PŘED ZAVEDENÍM ŠEDÉ ZÓNY	45
4.4 ZAVEDENÍ ŠEDÉ ZÓNY A KLASIFIKAČNÍCH HRANIC	46
4.5 ÚSPĚŠNOST KLASIFIKACE VYTVOŘENÉHO MODELU	48
5 SROVNÁNÍ VÝSLEDKŮ KLASIFIKACE S VYBRANÝMI MODELY	50
ZÁVĚR	55
POUŽITÁ LITERATURA	57
SEZNAM PŘÍLOH	59

SEZNAM TABULEK

Tabulka 1: Ztráta spojená s chybnou klasifikací	17
Tabulka 2: Klasifikační matice	19
Tabulka 3: Hodnocení Beermanovou diskriminační funkcí	24
Tabulka 4: Vyhodnocení indexu IN99	27
Tabulka 5: Schéma Q-test	28
Tabulka 6: Výpočet CF z provozní činnosti použitý pro účely modelu	32
Tabulka 7: Ukázka dat	35
Tabulka 8: Popisné statistiky celkových aktiv (v tis. Kč)	36
Tabulka 9: Aritmetické průměry a T-test	38
Tabulka 10: Klasifikační matice 1	39
Tabulka 11: Standardizované koeficienty 1	39
Tabulka 12: Průměry a mediány proměnné OA	40
Tabulka 13: Klasifikační matice 2	41
Tabulka 14: Standardizované koeficienty 2	41
Tabulka 15: Průměry a mediány proměnné PL	42
Tabulka 16: Klasifikační matice 3	43
Tabulka 17: Standardizované koeficienty 3	43
Tabulka 18: Prosté koeficienty modelu	44
Tabulka 19: Průměry kanonických proměnných	45
Tabulka 20: Klasifikační přesnost na testovacím vzorku	45
Tabulka 21: Klasifikační hranice modelu	47
Tabulka 22: Klasifikační matice ze souboru dat použitých pro tvorbu modelu	48
Tabulka 23: Případy v šedé zóně (vzorek užitý pro vytvoření modelu)	48
Tabulka 24: Klasifikační matice z testovacího vzorku dat	48
Tabulka 25: Případy v šedé zóně (testovací vzorek)	49
Tabulka 26: Klasifikační matice celého souboru	49
Tabulka 27: Počty případů v šedé zóně	49
Tabulka 28: Klasifikační úspěšnost vybraných modelů	51
Tabulka 29: Analýzu chyb a případů v šedé zóně	51
Tabulka 30: Správná klasifikace z celkového počtu případů	52
Tabulka 31: Zohlednění šedé zóny do přesnosti klasifikace	53
Tabulka 32: Chyby v klasifikaci podle typu	54

SEZNAM ILUSTRACÍ

Obrázek 1: Histogram vzorku podle celkových aktiv (celý soubor dat)	36
Obrázek 2: Porovnání struktury aktiv mezi skupinami (celý soubor dat)	37
Obrázek 3: Krabicový graf z proměnné OA	40
Obrázek 4: Krabicový graf z proměnné PL	42
Obrázek 5: Bodový graf dosaženého skóre podle skupin (testovací soubor dat)	46
Obrázek 6: Bodový graf a zavedení šedé zóny (celý soubor dat)	47

SEZNAM ZKRATEK A ZNAČEK

BDF	Beermanova diskriminační funkce
CF	(Cash flow) peněžní tok
DA	diskriminační analýza
DHM	dlouhodobý hmotný majetek
EAT	(Earnings after Taxes) čistý zisk
EBIT	(Earnings before Taxes and Interest) hrubý zisk před odečtením nákladových úroků
EBT	(Earnings before Taxes) hrubý zisk
FA	finanční analýza
CHK	chyba klasifikace
KFM	krátkodobý finanční majetek
LzPCF	likvidita z provozního cash flow
MDA	(Multiple Discriminant Analysis) multivariační diskriminační analýza
OA	obrat aktiv
OKEČ	oborová klasifikace ekonomických činností
PL	pohotová likvidita
ROA	(Return on Assets) rentabilita aktiv
VM	vytvořený model

ÚVOD

Diskriminační analýza (DA) patří mezi vícerozměrné statistické metody, která nachází uplatnění v různých oblastech, jako jsou například vyhodnocení psychologických testů, výzkum v medicíně, bankovníctví a analýza finančního zdraví podniku.

Vícerozměrnou diskriminační analýzu pro účely predikce bankrotu podniků využil jako první profesor Altman v roce 1968. Tento způsob sestavení predikčního modelu pomocí DA je patrně dodnes nejrozšířenější metodou tvorby modelu predikce finanční tísně.

Cílem práce je aplikovat metodu diskriminační analýzy na účetní data a následně sestavit model, který by co nejlépe posuzoval finanční zdraví podniku, a určil, zda podnik spěje k úpadku, či nikoliv. Model je zaměřen na podniky působící v České Republice ve zpracovatelském průmyslu.

První část práce je věnována teoretickému základu diskriminační analýzy. Poté jsou popsány vybrané populární modely zabývající se analýzou finančního zdraví podniků. Následuje metodika výběru vstupních dat a provedení samotné diskriminační analýzy. V závěru práce je testována přesnost klasifikace modelu, která je poté porovnána s vybranými modely obdobného typu a následuje diskuse výsledků.

1 DISKRIMINAČNÍ ANALÝZA

Diskriminační analýzu (DA) použil poprvé ve svých publikacích R. A. Fisher v roce 1936. Podstata diskriminační analýzy spočívá ve zkoumání závislosti jedné klasifikační (kvalitativní) proměnné na několika nezávislých kvantitativních proměnných. DA hledá zákonitosti, které vedly k rozdělení případů do skupin, a následně formuluje pravidlo, podle kterého je nový objekt zařazen do konkrétní skupiny. Předpokládáme, že jednotlivé statistické jednotky jsou rozděleny do skupin v rámci klasifikační proměnné a platí následující vztah:

$$2 \leq q < n. \quad (1)$$

Ve kterém q představuje počet obměn klasifikační proměnné, jenž musí být vyšší nebo rovno dvěma a zároveň je požadováno vyššího počtu statistických jednotek (n), než je počet obměn (skupin) klasifikační proměnné (q). Podle počtu obměn klasifikační proměnné rozlišujeme DA pro dvě skupiny a DA pro více skupin.

Rozlišujeme dvě základní funkce diskriminační analýzy:

- popisná – která s pomocí znaků X_j , ($j = 1, \dots, k$), kde k značí počet nezávislých proměnných, spočívá v nalezení statisticky nejvhodnějšího způsobu rozdělení mezi jednotlivými skupinami (q) v rámci klasifikační proměnné,
- klasifikační – která zařazuje do jedné z předem určených skupin novou statistickou jednotku charakterizovanou k znaky (proměnnými). [12]

1.1 Předpoklady použití diskriminační analýzy

Při užití diskriminační analýzy je vhodné, aby data vstupující do modelu splňovala následující předpoklady:

1. Vícerozměrné normální rozdělení

Potvrzení vícerozměrného normálního rozdělení vyžaduje především test významnosti jednotlivých diskriminačních proměnných a diskriminačních funkcí. Pokud data nepochází z normálního rozdělení, testy významnosti nemusí být platné a dochází i k postihnutí výsledků klasifikace. Studie však tvrdí, že celková chyba klasifikace není nesplněním předpokladu příliš narušena. Existují také neparametrické metody diskriminační analýzy, které jsou schopny pracovat s daty i při nesplnění tohoto předpokladu.

2. Přesně definované skupiny statistických jednotek

Skupiny mohou být definované:

- objektivními okolnostmi – OKEČ, kraj,
- kvalifikovaným posouzením – posouzení skupinou odborníků z dané oblasti,
- statistickými metodami – shluková analýza, kvartily demografických ukazatelů a další.

3. Významnost zvolených diskriminačních proměnných

před sestavením diskriminační funkce je doporučeno otestovat:

- Shodu rozptylů – kovarianční matice podle skupin by měly být přibližně stejné, aby bylo možné odvodit Fisherovu diskriminační funkci, při významnějších odlišnostech je vhodné použít kvadratickou diskriminační funkci. Míra, ve které porušení předpokladu vede k ovlivnění testu významnosti a odhadu klasifikační chyby, závisí na počtu diskriminačních proměnných a velikosti skupin. Minimální velikost výběru je 5 objektů na jednu diskriminační proměnnou, doporučené množství je však 20. Zároveň by mělo platit, že i počet případů v nejméně početné skupině je větší než počet diskriminačních proměnných.
- Shodu středních hodnot v jednotlivých skupinách – mezi průměry proměnných ve skupinách by měly být statisticky významné rozdíly. Pokud je na základě testů zjištěno, že proměnné dostatečně nerozlišují mezi existujícími skupinami, pak se doporučuje tyto proměnné z analýzy vyloučit. [12]

1.2 Popisná úloha diskriminační úlohy

Popisná úloha spočívá v odvození diskriminační funkce, či funkcí, které statisticky významně odlišují dvě případně více skupin. Následně je zkoumán vliv jednotlivých nezávislých proměnných na rozlišení skupin a jejich vliv na tvorbu výsledné hodnoty diskriminačního skóre.

1.2.1 Kanonická diskriminační analýza

Podstatou je nalézt co nejvhodnější způsob rozlišení mezi q skupinami, které jsou charakterizovány k nezávislými proměnnými, kdy předpokládáme, že známé proměnné nejlépe rozlišují mezi skupinami a pouze určíme jejich relativní váhu v diskriminační funkci.

Je třeba vyjádřit matici meziskupinové variability, čímž vyjádříme rozdíl vektorů průměrů skupin.

$$B = \sum_{m=1}^q n_m (\bar{x}_m - \bar{x})' (\bar{x}_m - \bar{x}) \rightarrow \max, \quad (2)$$

kde

B – matice meziskupinové variability,

n_m – počet statistických jednotek v m -té skupině,

\bar{x}_m – vektor průměrů v m -té skupině

\bar{x} – průměry v celé skupině

Střední hodnoty jednotlivých skupin musí být co nejvzdálenější. Čím vyšší je vzdálenost, tím lépe přispívá daný znak k rozlišení skupiny od ostatních.

Matice vnitroskupinové variability vyjadřuje oblast překrývání projekcí daných skupin. Vyjádříme ji následovně:

$$W = \sum_{m=1}^q \sum_{i=1}^n (x_{im} - \bar{x}_m)' (x_{im} - \bar{x}_m) \rightarrow \min, \quad (3)$$

kde

x_{im} - vektor hodnot i -té statistické jednotky v m -té skupině

Rozlišení mezi skupinami je tím lepší, čím je oblast překrývání menší. Optimální řešení obou požadavků nazýváme Fisherovo kanonické diskriminační kritérium (4).

$$F = \frac{|B|}{|W|} \rightarrow \max \quad (4)$$

Hledáme tedy vlastní vektory matice $A = W^{-1}B$ a jim příslušející vlastní čísla λ_h . Vlastní vektory pak představují koeficienty Fisherových lineárních diskriminačních funkcí.

$$Z_h(DS_h) = a_{1h}x_1 + a_{2h}x_2 + \dots + a_{kh}x_k, \quad (5)$$

$$h = 1, \dots, s,$$

$$s = \min(k, q - 1),$$

kde

$Z_h(DS_h)$ – Fisherova lineární diskriminační funkce,

a_{kh} – prosté koeficienty funkce,

x_k – nezávislá proměnná.

V případě, že je soubor rozdělen do dvou skupin, je zapotřebí pouze jedna kanonická diskriminační funkce. Pokud je skupin více, je nutné použít další vlastní čísla, tím získáme další kanonické diskriminační funkce. Tyto diskriminační funkce jsou vzájemně nezávislé a vyjadřují celkovou variabilitu původních proměnných.

V praktické části budou mimo jiné využívány standardizované koeficienty kanonické diskriminační funkce. Na základě prostých koeficientů a_{kh} užitých při výpočtu diskriminačního skóre nelze interpretovat přínos proměnných k diskriminaci. Standardizované koeficienty představují tradiční přístup k interpretování diskriminačních funkcí. Výpočet standardizovaných koeficientů je proveden vynásobením prostých koeficientů směrodatnými odchylkami vyjadřujícími míru vnitroskupinové variability odpovídajících původních veličin. Každý standardizovaný koeficient představuje relativní příspěvek svého diskriminátoru (proměnné) do Fisherovy lineární diskriminační funkce. Diskriminátory s relativně velkými koeficienty přispívají více do diskriminační síly diskriminační funkce než diskriminátory s menšími koeficienty. Znaménko ukazuje, že diskriminátor má buď kladný, nebo záporný příspěvek. Problémem standardizovaných koeficientů může být jejich nestabilita. [6] [11]

K výběru proměnných pro sestavení diskriminační funkce lze přistoupit dvěma způsoby:

- využít všech k nezávislých proměnných
- využít pouze vybrané nezávislé proměnné (kroková DA).

1.2.2 Kroková diskriminační analýza

Metoda již nepředpokládá, že všechny nezávislé proměnné nejlépe rozlišují mezi jednotlivými skupinami. Vybírají se pouze ty proměnné, které statisticky významně rozlišují mezi skupinami a z nich se až poté vytvoří diskriminační funkce. Existují různé metody krokové DA:

- Forward selection – do diskriminační funkce vstupují proměnné postupně a jsou vybrány ty proměnné, které nejvíce přispívají k diskriminaci. Pokud již není statisticky významný přínos k diskriminaci, žádná nová proměnná do funkce nevstoupí.
- Backward selection – do diskriminační funkce vstupují všechny proměnné a postupně se vyřazují ty, které pokud jsou vyřazeny, nezpůsobí statisticky významný úbytek míry diskriminace. Proces se zastaví, pokud by další vyřazení proměnné znamenalo významný pokles míry diskriminace.
- Stepwise selection – kombinace obou metod, kde do diskriminační funkce vstupují proměnné a vybírají se ty proměnné, které mají největší přínos z hlediska diskriminace. Zároveň se ověřuje, zda je možné vyřadit proměnné, bez statisticky významného úbytku míry diskriminace.

Tyto postupy dosahují obdobných výsledků, pokud jsou proměnné nekorelované. V případě vzájemné korelace proměnných dosahuje nejlepších výsledků metoda Stepwise selection. [12]

Při tvorbě modelu není využíváno krokové DA, ale přínos proměnných do modelu je hodnocen především s ohledem na standardizované koeficienty kanonické diskriminační funkce a další charakteristiky. Konkrétně je postup výběru proměnných popsán v kapitole 4.

1.3 Klasifikační úloha diskriminační analýzy

Klasifikační úloha umožňuje identifikaci nové statistické jednotky, která je charakterizována k znaky (proměnnými), do jedné z q skupin klasifikační proměnné. Poté je možné testovat účinnost klasifikačního kritéria na původním souboru.

Cílem popisné úlohy je nalézt diskriminační funkci, která by co nejlépe rozlišovala mezi skupinami. Cílem klasifikační úlohy je minimalizovat počet chybně klasifikovaných objektů. Pro tento účel je možné použití několika odlišných metod:

- kritická hodnota diskriminačního skóre,
- Bayesovská teorie rozhodování,
- klasifikační funkce,
- Mahalanobisova vzdálenost.

Vzhledem k zaměření práce je dále popsána pouze situace odpovídající klasifikaci do dvou skupin ($q = 2$). Tyto skupiny jsou označeny symboly 0 a 1.

Kritická hodnota diskriminačního skóre

Kritické diskriminační skóre plní funkci porovnávacího kritéria. S touto hodnotou se porovnávají individuální diskriminační skóre Z_i jednotlivých nezařazených statistických jednotek. Jednotky, které dosáhnou větší hodnoty, než je kritická hodnota (\bar{Z}_k), jsou zařazeny do jedné skupiny, ostatní jsou zařazeny do druhé skupiny. Kritické skóre závisí na četnosti skupin. Výpočet je proveden váženým aritmetickým průměrem.

$$\bar{Z}_k = \frac{n_0 \bar{Z}_0 + n_1 \bar{Z}_1}{n_0 + n_1}, \quad (6)$$

kde

\bar{Z}_0 - průměrné diskriminační skóre ve skupině 0,

\bar{Z}_1 - průměrné diskriminační skóre ve skupině 1,

n_0 – četnost případů ve skupině 0,

n_1 - četnost případů ve skupině 1.

Klasifikace i -té jednotky do skupiny 0 proběhne, pokud $\bar{Z}_k > Z_i$, do skupiny 1 pokud $\bar{Z}_k < Z_i$.

Bayesovská teorie rozhodování

Využívá informace o apriorních pravděpodobnostech a informace spojené s chybnou klasifikací. Výsledkem je získání aposteriorní pravděpodobnosti klasifikace daného objektu do konkrétní skupiny.

Zohlednění velikosti skupin má smysl pouze v případě, když skupiny nejsou stejně početné. V takovém případě i pravděpodobnost zařazení nové statistické jednotky do konkrétní skupiny musí být rozdílná. Předpokládejme, že π_0, π_1 je rozsah skupiny odpovídající apriorní pravděpodobnosti. V případě konkrétní jednotky, můžeme aposteriorní pravděpodobnost příslušnosti jednotky k dané skupině vyjádřit podle Bayesova vzorce jako:

$$\frac{\pi_h f_h(x)}{\pi_0 f_0(x) + \pi_1 f_1(x)}, \quad (7)$$

$$h = 0; 1.$$

Statistická jednotka bude zařazena do skupiny s vyšší aposteriorní pravděpodobností.

Do skupiny 0 zařazujeme pokud:

$$\frac{f_0(x)}{f_1(x)} \geq \frac{\pi_1}{\pi_0} \quad (8)$$

kde $f_0(x)$ a $f_1(x)$ jsou funkce hustoty pravděpodobnosti proměnných skupiny 0 a 1.

Pokud uvedená nerovnost neplatí, zařazujeme jednotku do skupiny 1.

Jako doplňující informaci je možno využít odhad ztráty z chybné klasifikace. Apriorní pravděpodobnost je v procesu rozhodování o klasifikaci upravena o ztrátu spojenou s chybnou klasifikací.

V následující tabulce označuje C ztrátu spojenou s chybnou klasifikací.

Tabulka 1: Ztráta spojená s chybnou klasifikací

		Skutečné zařazení jednotky	
		skupina 0	skupina 1
Předpokládané zařazení jednotky	skupina 0	$C(0 0) = 0$	$C(0 1) > 0$
	skupina 1	$C(1 0) > 0$	$C(1 1) = 0$

Zdroj: [12]

S upravenými apriorními pravděpodobnostmi vznikne nejmenší ztráta, pokud zařadíme novou statistickou jednotku do skupiny 0 v případě, že platí:

$$\frac{f_0(x)}{f_1(x)} \geq \frac{C(0|1)\pi_1}{C(1|0)\pi_0} \quad (9)$$

Pokud vztah výše neplatí, zařadíme statistickou jednotku do skupiny 1.

Klasifikační funkce

Spočívá v sestavení klasifikačních funkcí sestrojených pro každou skupinu zvlášť. Poté následuje výpočet klasifikačního skóre. V případě dvou skupin tedy budou pro každou jednotku vypočtena dvě skóre. Jednotka bude klasifikována do skupiny, jejíž skóre klasifikační funkce bude vyšší.

Mahalanobisova vzdálenost

Klasifikace je založena na určení Mahalanobisovi vzdálenosti mezi novou statistickou jednotkou a centroidem každé skupiny. Objekt je zařazen do skupiny, ke které dosahuje nejnižší Mahalanobisovu vzdálenost. [12]

1.3.1 Ověření přesnosti klasifikace

Použití diskriminační analýzy umožňuje ověření přesnosti klasifikace. Přesnost klasifikace ověřujeme na objektech, u kterých známe příslušnost ke skupině. Je možné použít následující metody:

- reklasifikace, resubstituce

pomocí klasifikačního kritéria se hodnotí objekty obsáhnuté v původním vzorku, které byly použity k odvození tohoto kritéria. Při použití této techniky dochází k nadhodnocení přesnosti, proto je tato technika používána v případech, kdy není možné použít jiný způsob ověření přesnosti.

- rozdělení výběrového souboru

původní soubor se náhodně rozdělí do dvou. První z nich je použit pro odhad diskriminační funkce. Druhý slouží ke klasifikaci pomocí odvozeného klasifikačního kritéria. Výsledkem je nevychýlený odhad míry přesnosti klasifikace.

Předpokladem je dostatečně velký rozsah výběrového souboru a preferuje se rozdělení na srovnatelně početné podsoubory. Větší spolehlivosti této metody je možné dosáhnout vícenásobným zopakováním rozdělení souboru a následným zprůměrováním výsledků.

- křížové ověření přesnosti

při odhadu klasifikačního kritéria se vynechá jeden objekt. Pomocí odvozeného klasifikačního kritéria se tento objekt klasifikuje. Postup se opakuje, dokud nejsou

klasifikovány všechny objekty. Tato metoda poskytuje nejméně vychýlený odhad přesnosti klasifikace, a tudíž je doporučována. [6] [12]

Výsledky z libovolné metody ověření klasifikace je možné zapsat např. pomocí klasifikační matice. Problémem je určení, jak velký poměr úspěšnosti je dostatečný. V každém případě by přesnost klasifikace jednotek měla být vyšší než náhodná klasifikace jednotek.

Klasifikační matice bude mít v rámci této práce podobu tabulky uvedené níže. Jedná se o situaci klasifikace do dvou skupin. Ve sloupci **% správně** nalezneme údaj o přesnosti klasifikace v rámci skupin v procentuálním vyjádření. **Modře** zbarvená pole tabulky představují počty správně zařazených případů. **Červená** pole v tabulce podávají informace o chybách v klasifikaci. Chyba klasifikace 1 představuje situaci, kdy model zařadí do skupiny 0 případ, který ve skutečnosti přísluší do skupiny 1. Analogicky je pak chyba klasifikace 0 opakem (případ příslušící do skupiny 0 je modelem klasifikován do skupiny 1).

Tabulka 2: Klasifikační matice

		% správně	Klasifikace modelu	
			0	1
Skutečnost	0	%	Správně	Chyba klasifikace 0
	1	%	Chyba klasifikace 1	Správně
Celkem		%	Σ	Σ

Zdroj: zpracováno na základě výstupu z programu Statistica 10

2 VYBRANÉ MODELY PRO POSOUZENÍ FINANČNÍHO ZDRAVÍ

Modely pro posouzení finančního zdraví podniku jsou součástí finanční analýzy (FA). Za obecný cíl FA je považováno:

- a) Posouzení finančního zdraví podniku v podobě logického průniku rentability a likvidity. Toto vymezení je však nedostatečné, proto je doplňováno alternativními cíly:
- b) Identifikace silných a slabých stránek podniku.
- c) Rozbor finanční situace podniku, ale i odvětví, resp. Státu.
- d) **Identifikace finanční tísně podniku**, což je situace, kdy má podnik takové problémy, které lze řešit pouze výraznými změnami v činnostech podniku, nebo ve způsobu financování. [8]

Za finančně zdravý podnik považuje anglosaská literatura takový podnik, který naplňuje v současnosti, ale perspektivně i v budoucnosti, smysl své existence. V tržních podmínkách je smysl existence podniku naplněn, pokud je podnik schopen dosahovat zhodnocení vloženého kapitálu podle představ investorů. Nestačí však, aby byl podnik rentabilní. Nutnou podmínkou finančně zdravého podniku je i dostatečná likvidita, tedy schopnost včas uhrazovat splatné závazky. [14]

Mezi vyšší metody finanční analýzy se řadí bankrotní a bonitní modely hodnotící finanční zdraví podniku. Tvorbou bankrotního modelu se tato práce zabývá.

Je nutné si uvědomit, k čemu predikční modely založené na diskriminační analýze slouží. Jedná se o metodu, která nevysvětluje proč se podnik ocitl v potížích, nýbrž se jedná o metodu, jež rozpoznává typické charakteristiky podniků v obtížích a následně zařazuje podniky s těmito znaky do bankrotní skupiny. V literatuře se objevuje trefné přirovnání tohoto nástroje k teploměru. [1]

Základní rozdělení modelů posuzujících finanční zdraví podniku rozlišuje mezi jednorozměrnými a vícerozměrnými modely. Častým dělením je také rozdělení modelů na bonitní a bankrotní.

Cílem jednorozměrných modelů je nalézt charakteristiku, která by souhrnně vyjádřila ekonomickou situaci podniku. Nejdříve jsou vybrány poměrové ukazatele, jejichž hodnota je transformována na body, ze kterých se vypočítá aritmetický průměr. Body jsou určeny podle bodové stupnice, jež je vytvořena na základě expertních metod.

Vícerozměrné modely používají sofistikovanější matematicko-statistické metody pro vytvoření modelu a vah u jednotlivých proměnných. Často je využívána právě diskriminační analýza. Mezi nepoužívanější modely patří Altmanovo Z-skóre, Tafflerův model, Index bonity a v podmínkách České republiky se hojně využívají indexy IN.

Bonitní modely – jedná se o hodnocení firmy koeficientem, který je složený z účelově vybrané kombinace poměrových ukazatelů. Výsledky jsou porovnávány s ostatními subjekty v oboru. Hodnocení tedy probíhá ex post a vede především k poznání příčin, které vedly k současné pozici podniku. Bonitní modely nejsou pro tuto práci stěžejní, jelikož vytvářený model je bankrotního typu.

Bankrotní modely – nebo predikční modely, jsou modely, které predikují vážné potíže finančního zdraví podniků. Modely jsou tvořeny z dat o podnicích, jež v minulosti skončily v úpadku. Výstupem modelů je výpočet hodnoty indexu, který vede ke klasifikaci podniku jako ohroženého úpadkem, neohroženého úpadkem, nebo model podnik zařadí do tzv. šedé zóny. [4] [15]

Výběr modelů popsaných v další části je ovlivněn tím, že využívají diskriminační analýzy, jako hlavního nástroje tvorby metody. V další části práce jsou detailněji popsány především tyto bankrotní modely: Altmanovo Z-skóre, Beermanova diskriminační funkce, Tafflerův index a indexy IN.

2.1.1 Altmanovo Z-skóre

Profesor Altman na základě diskriminační analýzy určil váhy k poměrovým ukazatelům klasifikační funkce. Původní vzorek tvořilo 66 výrobních a burzovně obchodovaných společností. Do jedné skupiny bylo zařazeno 33 podniků, které mezi lety 1946-1965 zbankrotovaly. Ve druhé skupině byl vzorek 33 náhodně zvolených výrobních podniků obdobného charakteru jako v první skupině, které existovaly ještě v roce 1965. Vzorek dat obsahoval podniky s aktivy od 1 do 30 mil. USD. [2]

Poté byla shromážděna účetní data o vybraných podnicích. A následně vybrány poměrové ukazatele, které budou nejlépe odlišovat mezi skupinami. Výslednou diskriminační funkci tvořilo těchto 5 proměnných:

$$X1 = \frac{\text{Working capital}}{\text{Total assets}} = \frac{\text{Pracovní kapitál}}{\text{Celková aktiva}};$$

$$X2 = \frac{\text{Retained earnings}}{\text{Total assets}} = \frac{\text{Zisk po zdanění} + \text{Nerozdělený zisk z minulých let}}{\text{Celková aktiva}};$$

$$X3 = \frac{\text{EBIT}}{\text{Total assets}} = \frac{\text{Zisk před zdaněním a úroky}}{\text{Celková aktiva}};$$

$$X4 = \frac{\text{Market value of equity}}{\text{Book value of total liabilities}} = \frac{\text{Tržní hodnota kapitálu (vlastního jmění)}}{\text{Celkové cizí zdroje (účetní hodnota)}};$$

$$X5 = \frac{\text{Sales}}{\text{Total assets}} = \frac{\text{Tržby}}{\text{Celková aktiva}}.$$

Klasifikační funkce vypadala následovně:

$$Z = 1,2 * X1 + 1,4 * X2 + 3,3 * X3 + 0,6 * X4 + 0,999 * X5. \quad (10)$$

Poté co algoritmus diskriminační analýzy zařadil podniky do dvou skupin, byla provedena analýza výsledků, z čehož vzešlo 14 chybně zařazených podniků, z toho 10 špatně klasifikovaných podniků dosáhlo skóre v intervalu (1,81; 2,67). Cílem diskriminační analýzy je maximalizovat poměr správně klasifikovaných subjektů. Jelikož k chybné klasifikaci docházelo především v uvedeném intervalu, jenž je zároveň pomyslným hraničním pásmem pro klasifikaci, byl do modelu zaveden pojem **šedá zóna**, kdy podniky dosahující skóre v intervalu nejsou klasifikovány ani do jedné skupiny, ale vzniká 3. skupina pro klasifikaci.

Po provedení empirického pozorování byla „šedá zóna“ rozšířena na interval (1,81; 2,99). Podniky, které dosahují nižších hodnot klasifikační funkce, než 1,81 jsou hodnoceny jako podniky spějící k bankrotu. Podniky dosahující skóre 3 a více jsou klasifikovány jako podniky neohrožené bankrotem. Ostatní podniky spadají do šedé zóny a nejsou tedy klasifikovány ani do jedné ze dvou skupin.

Altman na základě výsledků klasifikace určil konkrétní hodnotu skóre, které nejlépe určuje hranici mezi bankrotními a bonitními podniky. Hraniční bod byl nazván „Z value“ a jedná se o hodnotu Altmanovy diskriminační funkce $Z = 2,675$. [2]

Při testování úspěšnosti klasifikace bylo pozorováno, že model poměrně spolehlivě predikuje bankrot, pokud jsou dodána účetní data z podniku, který je v situaci 1 až 2 roky před samotným bankrotem. Spolehlivost modelu se snižuje s každým dalším rokem.

Nutno podotknout, že Altmanovo Z-skóre se stalo velmi populární a následovalo také několik modifikací.

Modifikace pro veřejně neobchodované podniky

Modifikace je určena pro podniky, které nejsou veřejně obchodovatelné. V modelu je upravena proměnná X_4 , kde tržní hodnotu kapitálu nahrazuje účetní hodnota vlastního kapitálu a celkové dluhy ve jmenovateli zůstávají neměnné. Mění se také hranice pro klasifikaci na $Z' > 2,9$ pro podniky neohrožené bankrotem a na $Z' < 1,23$ pro podniky ohrožené. [3]

$$Z' = 0,717 * X_1 + 0,847 * X_2 + 3,107 * X_3 + 0,420 * X_4 + 0,998 * X_5 \quad (11)$$

Další modifikací je model pouze se čtyřmi proměnnými, vyloučena z modelu byla proměnná X_5 (Tržby/Celková aktiva). Důvodem byla vysoká citlivost tržeb na odvětví. Hranice pro klasifikace jsou $Z'' > 2,6$ pro podniky v pásmu bezpečí, $Z'' < 1,1$ pro podniky v pásmu bankrotu. Hodnoty v intervalu $\langle 1,1; 2,6 \rangle$ pak řadí podnik do zóny neurčitosti.

$$Z'' = 6,56 * X_1 + 3,26 * X_2 + 6,72 * X_3 + 1,05 * X_4 \quad (12)$$

Nejvíce přispívá ke klasifikaci proměnná X_3 . Výsledky klasifikace Z'' byly téměř identické jako u modelu Z' . [10]

2.1.2 Beermanova diskriminační funkce

Metoda byla vyvinuta v Německu. Využívá 10 poměrových ukazatelů, což je v porovnání s ostatními modely poměrně velký počet. Autor zkoumal 21 podniků, které mezi lety 1966 až 1971 zbankrotovaly, či nikoliv. [7] [10]

$$B = 0,217 * X_1 - 0,63 * X_2 + 0,012 * X_3 + 0,077 * X_4 - 0,105 * X_5 - 0,813 * X_6 + 0,165 * X_7 + 0,161 * X_8 + 0,268 * X_9 + 0,124 * X_{10}, \quad (13)$$

kde

$$\begin{aligned} X_1 &= \frac{\text{Odpisy}}{\text{DHM}}; & X_2 &= \frac{\text{Přírůstek DHM}}{\text{Odpisy}}; \\ X_3 &= \frac{\text{Zisk}}{\text{Tržby}}; & X_4 &= \frac{\text{Závazky vůči bankám}}{\text{Závazky celkem}}; \\ X_5 &= \frac{\text{Zásoby}}{\text{Tržby}}; & X_6 &= \frac{\text{Cash flow}}{\text{Závazky celkem}}; \\ X_7 &= \frac{\text{Závazky celkem}}{\text{Aktiva}}; & X_8 &= \frac{\text{Zisk}}{\text{Aktiva}}; \\ X_9 &= \frac{\text{Tržby}}{\text{Aktiva}}; & X_{10} &= \frac{\text{Zisk}}{\text{Závazky celkem}}. \end{aligned}$$

Klíčová hodnota, která klasifikuje podnik na bonitní či bankrotní je 0,3. Vyšší hodnoty značí podnik bankrotní, nižší pak bonitní. Detailní hodnocení diskriminační funkce vyjadřuje následující tabulka.

Tabulka 3: Hodnocení Beermanovou diskriminační funkcí

Výsledek	Hodnocení	Podnik
$B \in \langle 0,35; \infty \rangle$	velmi špatná finanční situace	bankrotní
$B \in \langle 0,3; 0,35 \rangle$	špatná finanční situace	bankrotní
$B \in \langle 0,25; 0,3 \rangle$	průměrná finanční situace	bonitní
$B \in \langle 0,2; 0,25 \rangle$	dobrá finanční situace	bonitní
$B \in \langle -\infty; 0,2 \rangle$	velmi dobrá finanční situace	bonitní

Zdroj: [15]

Obdobně jako u Altmanovy analýzy i zde roste neúspěšnost predikce s prodlužující se dobou. Autor uvádí neúspěšnost predikce 9,5 % jeden rok před bankrotem. Čtyři roky před bankrotem dosahuje neúspěšnost predikce bankrotu 38,1 %. [10] [15]

2.1.3 Tafflerův index

Vznikl v roce 1977 jako reakce na Altmanovu analýzu. Byl vytvořen na vzorku Britských firem. První část vzorku tvořily podniky obchodované na London stock Exchange v letech 1968 až 1976, které zbankrotovaly. Druhou část vzorku tvořily náhodně zvolené solventní podniky. Celkem byl model vytvořen na vzorku 46 finančně stabilních a 46 bankrotních podniků. Na počátku byla využita množina 90 poměrových ukazatelů, z kterých byly vybrány pouze 4 klíčové, těm následně autoři přidělili váhy.

Tafflerův index nabývá dvou obměn, kterými jsou původní varianta a modifikovaná varianta. Kalkulace Tafflerova indexu vyžaduje odlišné vstupy v závislosti na tom, jaká varianta je zvolena. [1] [10]

Původní Tafflerův index

V původním Tafflerově indexu má nejvyšší váhu poměrový ukazatel zisk (před zdaněním)/krátkodobé závazky.

$$T1 = 0,53 * X1 + 0,13 * X2 + 0,18 * X3 + 0,16 * X4, \quad (14)$$

kde:

$$X1 = \frac{\text{Zisk}}{\text{Krátkodobé závazky}}; \quad X2 = \frac{\text{Oběžná aktiva}}{\text{Cizí kapitál}}$$
$$X3 = \frac{\text{Krátkodobé závazky}}{\text{Aktiva}}; \quad X4 = \frac{\text{Finanční majetek} - \text{Krátkodobé závazky}}{\text{Provozní náklady}}$$

Při hodnocení výsledku se nevyužívá tzv. šedé zóny. Podniky jsou rozděleny podle dosažené hodnoty indexu na bonitní a bankrotní. Pokud $T1$ je větší než 0 jedná se o bonitní podnik, pokud je však $T1$ nižší než 0 je podnik klasifikován jako bankrotní. [15]

Modifikovaný Tafflerův index

Rozdíl oproti původní verzi spočívá ve změně posledního poměrového ukazatele, což má za následek odlišné hranice pro klasifikaci a je nově zavedena šedá zóna. Při hodnotě indexu $T2$ nad 0,3 se jedná o bonitní podnik. Mezi hodnotami 0,2 a 0,3 se jedná o podnik v šedé zóně, kdy nejsme schopni jednoznačně klasifikovat podnik. Podniky s nižší hodnotou než 0,2 jsou klasifikovány jako bankrotní. [15]

$$T2 = 0,53 * X1 + 0,13 * X2 + 0,18 * X3 + 0,16 * X4, \quad (15)$$

kde

$$X1 = \frac{\text{Zisk před zdaněním}}{\text{Krátkodobé závazky}}; \quad X2 = \frac{\text{Oběžná aktiva}}{\text{Cizí kapitál}};$$
$$X3 = \frac{\text{Krátkodobé závazky}}{\text{Aktiva}}; \quad X4 = \frac{\text{Tržby}}{\text{Aktiva}}$$

2.1.4 Indexy IN

Autory jsou Inka a Ivan Neumaierovi. Postupem času byly vytvořeny čtyři indexy. První vznikl v roce 1995 a byl nazván index IN95, další v roce 1999 s názvem index IN99, poté v roce 2001 index IN01 a prozatím poslední index IN05 z roku 2005.

Indexy jsou specifické tím, že jsou vytvářeny v podmínkách ČR z dat českých podniků. Další výhodou je přizpůsobení českým účetním standardům a jednoznačnost použitých poměrových ukazatelů.

Index IN95

Jiným názvem také věřitelská varianta. Nejvýznamnější ukazatel představuje podíl zisku na celkových aktivech (ROA). Součástí modelu je také ukazatel podílu závazků po splatnosti na celkových výnosech, který má významnou zápornou váhu, což je dáno velkou mírou platební neschopnosti českých podniků v 90. letech.

$$IN95 = 0,022 * X1 + 0,11 * X2 + 8,33 * X3 + 0,52 * X4 + 0,1 * X5 - 16,8 * X6, \quad (16)$$

kde:

$$\begin{aligned} X1 &= \frac{\text{Aktiva}}{\text{Cizí zdroje}}; & X2 &= \frac{\text{Zisk před zdaněním}}{\text{Nákladové úroky}}; \\ X3 &= \frac{\text{Zisk před zdaněním}}{\text{Aktiva}}; & X4 &= \frac{\text{Výnosy}}{\text{Aktiva}}; \\ X5 &= \frac{\text{Oběžná aktiva}}{\text{Kr. cizí kapitál}}; & X6 &= \frac{\text{Závazky po splatnosti}}{\text{Výnosy}}. \end{aligned}$$

Index hodnotí podniky, které dosáhnou hodnoty vyšší než 2, jako bonitní. Při dosažení hodnoty mezi 1 a 2 nelze s určitostí klasifikovat, protože se jedná o šedou zónu. Dosažením hodnoty indexu nižší než 1 je poté klasifikován podnik jako bankrotní.

Index IN99

Nebo také vlastnická varianta indexu. Na rozdíl od ostatních zmiňovaných modelů se jedná o **bonitní model**. Výsledkem metody již není predikce bankrotu, ale určení, zda podnik tvoří, nebo netvoří hodnotu.

$$IN99 = -0,017 * X1 + 4,573 * X2 + 0,481 * X3 + 0,015 * X4, \quad (17)$$

kde

$$\begin{aligned} X1 &= \frac{\text{Aktiva}}{\text{Cizí zdroje}}; & X2 &= \frac{\text{Zisk}}{\text{Aktiva}}; \\ X3 &= \frac{\text{Výnosy}}{\text{Aktiva}}; & X4 &= \frac{\text{Oběžná Aktiva}}{\text{Kr. cizí kapitál}} \end{aligned}$$

Vyhodnocení výsledného indexu nalezneme v následující tabulce.

Tabulka 4: Vyhodnocení indexu IN99

Výsledek	Hodnocení
$IN99 \in (2,070; \infty)$	podnik tvoří hodnotu
$IN99 \in (1,590; 2,070)$	podnik spíše tvoří hodnotu
$IN99 \in (1,220; 1,590)$	šedá zóna
$IN99 \in (0,684; 1,220)$	podnik spíše netvoří hodnotu
$IN99 \in (-\infty; 0,684)$	podnik netvoří hodnotu

Zdroj: [15]

Index IN01

Neboli komplexní varianta indexu IN. Jedná se o model, jehož cílem je predikce bankrotu. Oproti indexu $IN95$ se liší váhami, ale i vyřazením proměnné Závazky po splatnosti/Výnosy a logicky vede i k odlišné klasifikaci hodnot indexu.

$$IN01 = 0,13 * X1 + 0,04 * X2 + 3,92 * X3 + 0,21 * X4 + 0,09 * X5, \quad (18)$$

kde:

$$X1 = \frac{\text{Aktiva}}{\text{Cizí zdroje}}; \quad X2 = \frac{\text{Zisk}}{\text{Nákladové úroky}}; \quad X3 = \frac{\text{Zisk}}{\text{Aktiva}};$$

$$X4 = \frac{\text{Výnosy}}{\text{Aktiva}}; \quad X5 = \frac{\text{Oběžná aktiva}}{\text{Kr. cizí kapitál}}$$

Podniky jsou poté klasifikovány jako bonitní, pokud hodnota indexu dosáhne hodnoty v intervalu $(1,77; \infty)$. Šedá zóna se nachází v intervalu $(0,75; 1,77)$. Model $IN01$ klasifikuje podnik jako bankrotní, jejichž index dosáhne hodnoty v intervalu $(-\infty; 0,75)$.

Index IN05

Modifikace předchozího indexu $IN01$. Bankrotně/bonitní model lišící se především změnou hodnotících intervalů.

$$IN05 = 0,13 * X1 + 0,04 * X2 + 3,97 * X3 + 0,21 * X4 + 0,09 * X5, \quad (19)$$

kde

$$X1 = \frac{\text{Aktiva}}{\text{Cizí zdroje}}; \quad X2 = \frac{\text{Zisk}}{\text{Nákladové úroky}};$$

$$X3 = \frac{\text{Zisk}}{\text{Aktiva}}; \quad X4 = \frac{\text{Výnosy}}{\text{Aktiva}}; \quad X5 = \frac{\text{Oběžná aktiva}}{\text{Kr. cizí kapitál}}$$

Změna šedé zóny na interval od 0,9 do 1,6. Hodnoty nad hranicí šedé zóny jsou klasifikovány jako bonitní. Hodnoty pod hranicí šedé zóny jako bankrotní. [15]

2.1.5 Další vybrané modely

Modelů varujících před možným bankrotem je mnoho, liší se zaměřením na konkrétní odvětví ekonomiky, původem vzorku, metodikou a dalšími charakteristikami. Některé další z nich jsou zmíněny níže.

Quick test (Kralickův Q-test)

Metoda byla pravděpodobně vytvořena v bankovním sektoru tehdejší SRN v 50. a 60. letech 20. století. Oficiální datum vzniku je udáváno až v roce 1990. Postupně byla využívána i v průmyslu a dodnes je v našich podmínkách poměrně široce používána. Jedná se o model, který stojí na pomezí bankrotních a bonitních modelů.

Metoda je definována následujícím schématem:

Tabulka 5: Schéma Q-test

Hodnota a hodnocení ukazatele					
Ukazatel	velmi dobrý	dobrý	střední	špatný	ohrožen insolvenčí
	(1)	(2)	(3)	(4)	(5)
VK/A	>30 %	>20 %	>10 %	<10 %	negativní
(CF/T)*100	>10 %	>8 %	>5 %	<5 %	negativní
ROA (s úroky)	>15 %	>12 %	>8 %	<8 %	negativní
Doba splácení v letech	<3 roky	<5 let	<12 let	>12 let	>30 let

Zdroj: [8] (4)

Čtyři kritéria jsou známkována podle schématu a celková známka se získá sečtením čtyř jednotlivých známek a vydělením součtu čtyřmi. Následně dochází ke klasifikaci podniku podle dosažené známky. Model nezahrnuje žádnou šedou zónou a nevyužívá váhy. [8]

A skóre

Za zmínku jistě stojí model A skóre z roku 1976. Od ostatních uvedených modelů je odlišný především čerpáním kvalitativních informací namísto kvantitativních obsažených v účetních výkazech. Problémy diagnostikuje na základě posuzování schopnosti managementu. Model vychází z předpokladu, že finanční nestabilita podniku je způsobena chybami v řízení podniku.

Model charakterizuje hodnotící kritéria. Ta jsou rozdělena na nedostatky, chyby, příznaky a dále členěna. Příklady kritérií jsou zhoršující se Z-skóre, slabý finanční ředitel, neodůvodněné

zadlužení u bank, chybějící rozpočtová kontrola a další. Kritéria jsou bodově ohodnocena a je určena hranice nebezpečí. [10]

3 VÝBĚR DAT PRO DISKRIMINAČNÍ ANALÝZU

Kromě již v práci zmíněných doporučení a podmínek pro použití diskriminační analýzy je třeba vybrat vhodná data. Při použití nevhodně vybraných dat může dojít ke zkreslení výsledků diskriminační analýzy, a tudíž ke snížení schopnosti klasifikace u nových případů.

Autoři zabývající se touto problematikou obecně doporučují do vzorku dat vybírat podniky s obdobnými charakteristikami jako je velikost podniku, odvětví, stát a ideálně i časové období. Tímto vymezením by teoreticky mělo dojít ke zvýšení úspěšné klasifikace výsledné metody, ale model poté ztrácí svou obecnost a je určen pro specifické využití. Vytvářený model a předpoklady, za kterých je sestaven, jsou detailně popsány v této a následující kapitole.

3.1 Rozlišení bonitních a bankrotních podniků

Velmi důležitá je definice selhávajícího podniku. Jak plyne z podmínek diskriminační analýzy, je nutné jasné vymezení skupin. V případě této práce, to bude okamžik, kdy je podnik podle platné legislativy ČR prohlášen za podnik v úpadku. Zákon č. 182/2006 (insolvenční zákon) definuje v paragrafu 3 úpadek následovně:

„(1) Dlužník je v úpadku, jestliže má

a) více věřitelů a

b) peněžité závazky po dobu delší 30 dnů po lhůtě splatnosti a

c) tyto závazky není schopen plnit

(dále jen "platební neschopnost").

(2) Má se za to, že dlužník není schopen plnit své peněžité závazky, jestliže

a) zastavil platby podstatné části svých peněžitých závazků, nebo

b) je neplní po dobu delší 3 měsíců po lhůtě splatnosti, nebo

c) není možné dosáhnout uspokojení některé ze splatných peněžitých pohledávek vůči dlužníku výkonem rozhodnutí nebo exekucí, nebo

d) nesplnil povinnost předložit seznamy uvedené v § 104 odst. 1, kterou mu uložil insolvenční soud.

(3) Dlužník, který je právnickou osobou nebo fyzickou osobou – podnikatelem, je v úpadku i tehdy, je-li předlužen. O předlužení jde tehdy, má-li dlužník více věřitelů a souhrn jeho závazků převyšuje hodnotu jeho majetku. Při stanovení hodnoty dlužníkovy majetku se přihlíží také k

další správě jeho majetku, případně k dalšímu provozování jeho podniku, lze-li se zřetelem ke všem okolnostem důvodně předpokládat, že dlužník bude moci ve správě majetku nebo v provozu podniku pokračovat.

(4) O hrozící úpadek jde tehdy, lze-li se zřetelem ke všem okolnostem důvodně předpokládat, že dlužník nebude schopen řádně a včas splnit podstatnou část svých peněžitých závazků.“ [16]

Takto klasifikované podniky vstoupí do diskriminační analýzy jako objekty ve skupině 1 (bankrotní podniky) v rámci klasifikační proměnné. Výběr konkrétních podniků a jejich účetních dat je proveden pomocí databáze Magnus. Do vytvářeného modelu vstupovala data za období jeden rok předcházející úpadku.

Podniky v bonitní skupině nebyly v době sběru dat v úpadku a nepředpokládají se možné problémy s finančním zdravím podniku v blízké budoucnosti.

Důležitým předpokladem modelu jsou také „normální“ ekonomické a finanční scénáře. Modely většinou nezahrnují možnost, že úpadek podniku byl úmyslný, či způsoben řízenou kriminální činností. [4]

Vzorek dat obsahuje vyvážený soubor vstupních dat, tedy stejný počet podniků v obou skupinách. V rámci reprezentativnosti vzorku je ideální vybírat podniky náhodně.

3.2 Výběr proměnných

Výběr proměnných je ovlivněn výše popsány modely, které se problematikou DA za účelem predikce bankrotu zabývají. Některé proměnné byly zařazeny na základě úsudku autora.

Následuje popis analyzovaných proměnných, které jsou dále testovány a případně vyřazovány z modelu zejména na základě toho, jak přispívají ke klasifikaci.

Analyzované proměnné

U vybraných proměnných je kladen důraz na významnost proměnných pro diskriminační analýzu. Konkrétně budou analyzovány tyto ukazatele:

$$\text{Pohotová likvidita (PL)} = \frac{\text{Krátkodobé pohledávky} + \text{KFM}}{\text{Krátkodobé cizí zdroje}} \quad (20)$$

KFM v čitateli značí krátkodobý finanční majetek. Ukazatel pohotové likvidity neboli likvidity II. stupně na rozdíl od běžné likvidity (III. stupně) nebere v úvahu celková oběžná aktiva. Ukazatel proto nabývá nižších, či ve výjimečných případech stejných hodnot jako ukazatel likvidity III. stupně.

$$\text{Celková zadluženost (CZ)} = \frac{\text{Cizí zdroje}}{\text{Aktiva celkem}} \quad (21)$$

Jeden ze základních ukazatelů zadluženosti, což je z hlediska vytvářeného modelu klíčová proměnná. Empiricky jsou zjištěny odchylky průměrných hodnot na základě příslušnosti k odvětví. Přesto je předpokládána klíčová významnost ukazatele pro DA.

$$\text{Výnosnost celkových aktiv (ROA)} = \frac{\text{Čistý zisk (EAT)}}{\text{Aktiva celkem}} \quad (22)$$

ROA je jedním z nejrozšířenějších poměrových ukazatelů. Řadí se mezi ukazatele rentability a představuje výsledek podnikového snažení. ROA nabývá různých obměn podle toho, jaký druh zisku je použit v čitateli. Pro účely této práce byl vybrán čistý zisk po zdanění (EAT). [13]

$$\text{Likvidita z provozního CF (LzPCF)} = \frac{\text{CF z provozní činnosti}}{\text{Krátkodobé cizí zdroje}} \quad (23)$$

Ukazatel je určen k hodnocení likvidity a je sestaven na bázi peněžních toků (CASH FLOW - CF). Vztah mezi CF z provozní činnosti a krátkodobými cizími zdroji vyjadřuje schopnost podniku splácet krátkodobé závazky z vytvořeného provozního CF. Konkrétní způsob výpočtu ukazatele provozního CF nalezneme v tabulce níže. Pro účely této práce je důležitý přesný popis výpočtu proměnných především v podobě, ve které vstupují do modelu.

Tabulka 6: Výpočet CF z provozní činnosti použitý pro účely modelu

Operace	Položka
	hospodářský výsledek (EAT)
+	odpisy DHM
+	změna ¹ stavu rezerv v provozní oblasti
+	změna - krátkodobé bankovní úvěry
+	změna - krátkodobé závazky
+	změna - časové rozlišení pasiv
-	změna - časové rozlišení aktiv
-	změna - pohledávky
-	změna - zásoby

Zdroj: Podle [9], [13]

¹ změna = hodnota položky v roce (T) – hodnota položky v roce (T – 1)

$$\text{Obrat aktiv(OA)} = \frac{\text{Tržby}}{\text{Aktiva celkem}} \quad (24)$$

Ukazatel poměřuje tokovou veličinu (tržby) k veličině stavové (aktiva). Výsledná hodnota pomáhá zjistit, zda je velikost aktiv přiměřená hospodářským aktivitám podniku. Jedná se o jeden z ukazatelů nejvíce ovlivněných příslušností podniku k odvětví. [9]

$$P1 = \frac{\text{Oběžná aktiva} - \text{Krátkodobé závazky} - \text{Bankovní úvěry}}{\text{Aktiva celkem}} \quad (25)$$

Proměnná výše je inspirována ČPK/celková aktiva, kde ČPK značí čistý pracovní kapitál. Tuto proměnnou využívá i Altmanův model. Drobná změna spočívá v čitateli. Konkrétně se od oběžných aktiv odečítají veškeré bankovní úvěry, nikoliv pouze krátkodobé bankovní úvěry. Proměnné ČPK/celková aktiva a proměnná P1 byly testovány pomocí dvouvýběrového t-testu a vizuálně pomocí krabicového grafu, výsledkem bylo zjištění mírně lepší diskriminační schopnosti proměnné P1.

$$P2 = \frac{\text{Nerozdělený zisk z minulých let} + \text{HV běžného období}}{\text{Aktiva celkem}} \quad (26)$$

Ukazatel výše měří kumulativní zisk zůstávající v podniku a poměřuje ho s celkovými aktivy. Jedná se o proměnnou, která zvýhodňuje stabilní podnik generující zisk po delší časové období.

3.3 Výběr vzorku podniků

Při výběru vzorku podniků bylo přihlíženo k několika důležitým faktorům. DA vyžaduje rozdělení podniků do dvou skupin. V našem případě bonitní podniky a podniky bankrotní (v úpadku). Bankrotní i bonitní podniky a jejich účetní data byla získána z databáze Magnus společnosti Bisnode. Bankrotní podniky jsou, nebo byly v úpadku podle české legislativy.

Skupina bonitních podniků byla vybrána ze stejného souboru dat. Pro zaručení objektivitu výběru byl použit generátor náhodných čísel a následný výběr podniků v bonitní skupině je tedy náhodný.

Podmínky pro výběr podniků jsou inspirovány modelem prof. Altmana. Ten mimo jiné uvádí, že není vhodné vybírat podniky příliš malé, kvůli nedostupnosti dat. Naopak největší podniky se dostávají do úpadku ojedinele a datový soubor by byl tedy příliš malý. Při volbě výběru podniků z databáze Magnus bylo určeno pásmo celkových aktiv, aby nedošlo k zahrnutí

nejmenších podniků, nebo největších podniků do analýzy, jejichž zařazení by mohlo zkreslit výstup analýzy.

Co se velikosti podniku týče, tak je možné považovat tuto charakteristiku za diskriminační, protože je prokázán vliv velikosti aktiv na možný úpadek (malé firmy bankrotují častěji). Z tohoto důvodu dochází při výběru datového souboru k **optimalizaci struktury aktiv** u obou skupin. [10]

Důležitou charakteristikou vybraných dat je také příslušnost všech podniků do kategorie klasifikace ekonomických činností CZ NACE kategorie **C – Zpracovatelský průmysl**. Jedná se o podniky zabývající se hlavně výrobou. Tato sekce zahrnuje mechanickou, fyzikální nebo chemickou přeměnu materiálů nebo komponentů na nové produkty, ačkoliv toto pravidlo nelze použít jako jednotné univerzální kritérium. [5]

Obecné podmínky pro zařazení podniků do vzorku dat. Platí **pro bonitní i bankrotní skupinu**:

- Působnost v ČR.
- Právní forma podnikání akciová společnost a společnost s ručením omezeným.
- Velikost aktiv je omezena zdola 70 mil. Kč a shora 2 mld. Kč. Hranice byla určena především na základě dostupnosti dat podniků v úpadku a na základě úsudku autora.
- Dostupnost účetních dat v databázi – údaje minimálně za dvě účetní období před úpadkem, nebo v případě bonitní skupiny roky 2013,2014. Data ze 2 účetních období jsou nutná pro určení provozního CF. Všechny ostatní proměnné zahrnují data pouze jeden rok před úpadkem, nebo rok 2014 (bonitní).
- Zpracovatelský průmysl (CZ NACE)

Podmínky pro zařazení podniku do skupiny **bonitních**:

- Nevyhlášen úpadek a neprobíhá řešení úpadku (reorganizace, konkurs, oddlužení, a jiné způsoby) k datu exportu dat z databáze.
- Dostupnost účetních dat za roky 2013, 2014. U bonitní skupiny nebyla vybrána nejnovější data záměrně, aby nedošlo k situaci, kdy podnik zařazený v bonitní skupině skončí v blízké budoucnosti v úpadku.
- Velikost aktiv vybraných bonitních podniků je zvolena s přihlédnutím ke struktuře bankrotních podniků. V rámci snahy o objektivně náhodný výběr bonitních podniků bylo využito generátoru náhodných čísel.

- Období využívaných účetních dat bonitních podniků je rok 2013 a 2014.

Podmínky pro zařazení podniku do skupiny **bankrotních**:

- V databázi Magnus jsou to podniky vedené jako podniky v úpadku (ve všech typech kromě stavu úpadku „Mylný zápis do rejstříku“ a stavu „Zrušený“)
- Počáteční datum zahájení řízení o úpadku je rok 2005
- Splňují obecné podmínky pro zařazení (viz výše).

Celkem bylo vybráno 65 podniků v úpadku a 65 podniků, které jsou klasifikovány jako bonitní. Celkem je připraveno pro analýzu **130 podniků**. Do samotné tvorby modelu vstoupí ale pouze jedna část podniků (33 bonitních a 33 bankrotních). Na druhé části bude následně testována úspěšnost klasifikace zhotoveného modelu (podrobněji v kapitole 4).

Tabulka níže zobrazuje ukázkou dat vstupujících do procesu tvorby modelu (viz příloha A). Testovací skupinu od skupiny pro tvorbu modelu odlišuje prázdné pole ve sloupci TEST. S. Prázdné pole ve sloupci ROK ÚPADKU představuje skutečnost, že podnik do doby extrakce dat nebyl v úpadku. ROK ÚČ. DAT je účetní období, ze kterého jsou vypočteny proměnné. Výpočty a celé názvy proměnných jsou popsány v podkapitole 3.2.

Tabulka 7: Ukázka dat

IČ PODNIKU	ROK ÚČ. DAT	ROK ÚPADKU	SKUP.	TEST. S.	AKTIVA CELKEM	ROA	CZ	P1	P2	OA	LzPCF	PL
14869799	2014		0	0	74681	-0.012	0.795	-0.230	-0.202	1.928	0.026	0.199
49790331	2014		0		378998	0.131	0.096	0.503	0.698	0.949	1.962	5.715
49240013	2014	2015	1		72678	-1.132	1.987	-1.012	-4.409	0.522	0.159	0.037
45475148	2015	2016	1	1	442625	0.008	0.422	0.301	0.604	0.652	0.107	0.566

Zdroj: vlastní zpracování na základě dat z databáze Magnus (Příloha A)

Velikostí aktiv vzorku podniků se bude práce detailněji zabývat, jelikož se jedná o důležitou charakteristiku podávající informace o tom, na jak velké podniky (podle velikosti aktiv) je ideální model aplikovat.

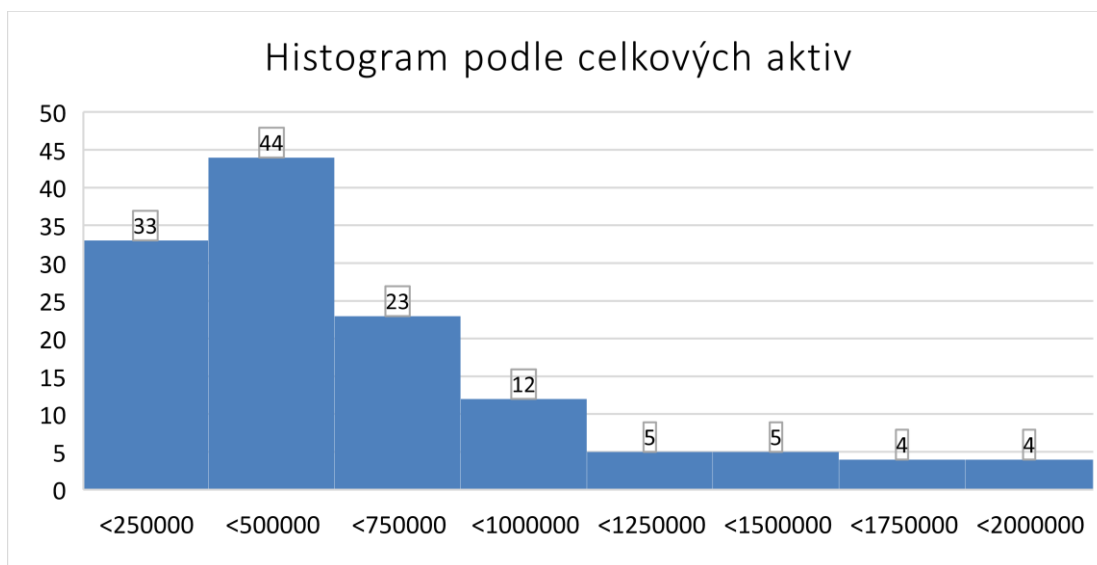
Základní popisné statistiky celkových aktiv jsou k vidění v následující tabulce. Průměrná výše aktiv v testovaném souboru je 554 mil. Kč, ale medián dosahuje hodnoty přes 389 mil. Kč. Můžeme konstatovat, že polovina podniků nedosahuje hodnoty celkových aktiv 390 mil. Kč. Teoreticky by pro zpřesnění klasifikační schopnosti měl být rozdíl mezi minimem a maximem co nejmenší, ale výsledný model vytvářený pouze pro příliš specifickou skupinu pozbývá významu jednoduchého obecného testu finančního zdraví, který se tato práce snaží sestavit.

Tabulka 8: Popisné statistiky celkových aktiv (v tis. Kč)

	Průměr	Medián	Minimum	Maximum
AKTIVA CELKEM	554260	389695	72678	1942402

Zdroj: vlastní zpracování, výstup z programu Statistica

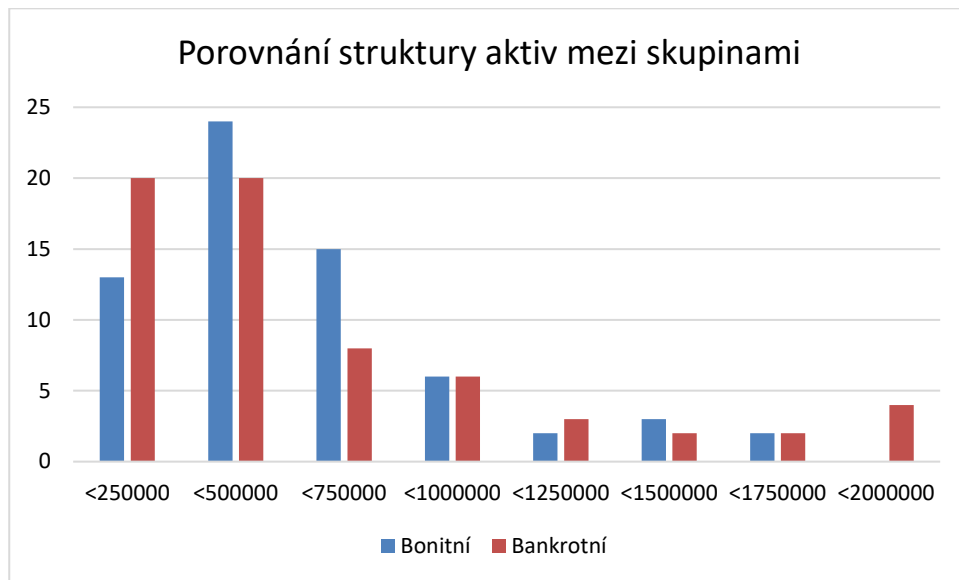
Strukturu podniků ve vzorku podle velikosti aktiv zobrazuje následující histogram. Z grafu vyplývá skutečnost, že téměř 80 % souboru tvoří podniky s celkovými aktivy menšími než 750 mil. Kč. Nejčetnější je pak skupina podniků s aktivy mezi 250 mil. Kč a 500 mil. Kč.



Obrázek 1: Histogram vzorku podle celkových aktiv (celý soubor dat)

Zdroj: vlastní zpracování (MS Excel)

Následující graf znázorňuje strukturu aktiv při rozlišení na skupiny bankrotních a bonitních podniků. Skupiny nemají zcela stejnou strukturu velikosti aktiv, což není pro tvorbu modelu nutné. Všechny proměnné jsou ve formě poměrových ukazatelů, tudíž drobné rozdíly v absolutní velikosti aktiv nejsou významné. Vizually je možné potvrdit přibližnou shodu v rozložení struktury aktiv mezi skupinami.



Obrázek 2: Porovnání struktury aktiv mezi skupinami (celý soubor dat)

Zdroj: vlastní zpracování (MS Excel)

4 TVORBA MODELU

Do modelu vstoupily proměnné a podniky definované v předchozí kapitole. Konkrétně tedy 130 podniků a 7 proměnných (PL, CZ, ROA, LzPCF, OA, P1 a P2). V první fázi tvorby modelu došlo k rozdělení skupiny podniků na dvě skupiny. První skupina se skládá z 33 bonitních a 33 podniků v úpadku. Tato skupina bude dále použita pro sestavení modelu. Druhá skupina poté bude sloužit jako testovací soubor. Veškeré analýzy v této podkapitole jsou provedené na množině podniků v první skupině.

4.1 Výběr proměnných

V první fázi tvorby modelu je vytvořen model se všemi 7 proměnnými pomocí kanonické diskriminační analýzy. Z výstupu modelu je zhodnocena klasifikační přesnost, standardizované a prosté koeficienty.

Tabulka níže představuje základní charakteristiku důležitou pro primární rozlišení přínosnosti proměnných do modelu. Jedná se o aritmetické průměry kategorizované dle skupin.

Tyto průměry mohou být základním indikátorem toho, zda budou proměnné přínosné pro tvorbu modelu. Dvouvýběrový t-test zkoumá, zda jsou rozdíly ve středních hodnotách mezi skupinami statisticky významné, či nikoliv. Vyšší p hodnota pak indikuje nižší statistickou významnost rozdílu mezi středními hodnotami. Z testu tedy vzešlo, že proměnné OA, LzPCF a PL mají nejbližší k nezamítnutí nulové hypotézy o **shodě středních hodnot mezi skupinami 0 a 1**.

Tabulka 9: Aritmetické průměry a T-test

Proměnná	Průměr (0)	Průměr (1)	t	sv	p
ROA	0.059	-0.170	5.895	64.000	0.000
CZ	0.487	0.935	-6.024	64.000	0.000
P1	0.184	-0.306	5.289	64.000	0.000
P2	0.181	-0.468	4.797	64.000	0.000
OA	1.595	1.222	1.391	64.000	0.169
LzPCF	0.417	0.072	2.182	64.000	0.033
PL	2.048	0.669	2.125	64.000	0.037

Zdroj: výstup z programu Statistica

Klasifikační přesnost modelu se 7 proměnnými dosahuje celkové úspěšnosti 86,4 % (viz následující tabulka). Model lépe klasifikoval bonitní podniky (skupina 0), o něco hůře pak podniky bankrotní (skupina 1).

Tabulka 10: Klasifikační matice 1

		% správně	Klasifikace modelu	
			0	1
Skutečnost	0	90.9	30	3
	1	81.8	6	27
Celkem		86.4	36	30

Zdroj: výstup z programu Statistica


Informaci o významnosti jednotlivých proměnných v rámci modelu nám napoví standardizované koeficienty (viz tabulka níže), kde vyšší absolutní hodnota koeficientu určuje vyšší významnost proměnné a naopak. Z hodnot je zřejmá dominance proměnných ROA a CZ. Poté následují proměnné LzPCF, P1, P2 a PL. Proměnná OA se zdá být pro model nejméně významná. Následuje průzkum proměnné OA a jejich charakteristik.

Tabulka 11: Standardizované koeficienty 1

Proměnná	Kořen
ROA	0.879
CZ	-0.773
PL	0.192
LzPCF	-0.410
P1	0.296
P2	-0.207
OA	0.013

Zdroj: výstup z programu Statistica

V krabicovém grafu (obrázek níže) vidíme důvod, proč je pro diskriminační analýzu proměnná nevhodná. Podniky v bankrotní i v bonitní skupině dosahují obdobných hodnot proměnné OA (obrat aktiv). Box ohraničuje středních 60 % podniků, tedy bez dolních a horních 20 % případů seřazených podle velikosti proměnné OA. Boxy obou skupin leží téměř ve stejném intervalu. Z tohoto důvodu můžeme konstatovat, že proměnná nemá diskriminační potenciál, proto je zbytečné zařadit tuto proměnnou do modelu.



Obrázek 3:Krabicový graf z proměnné OA

Zdroj: výstup z programu Statistica

Při pohledu na tabulku níže jsou rozdíly v aritmetických průměrech i v mediánu mezi skupinami. Nicméně rozlišení je nedostatečné a často dochází k překrývání hodnot mezi skupinami.

Tabulka 12: Průměry a mediány proměnné OA

Skupina	Průměr	Medián
0	1.595	1.351
1	1.222	0.959

Zdroj: výstup z programu Statistica

Po vyřazení proměnné je nutné znovu provést diskriminační analýzu. Pokud dojde k zásadnímu zhoršení klasifikační úspěšnosti modelu po vyřazení proměnné OA, bude tato proměnná do modelu navracena.

V tabulce pod odstavcem jsou výsledky klasifikace modelu po vyřazení proměnné OA. Ke zhoršení klasifikační schopnosti oproti modelu obsahující OA nedošlo, ba naopak došlo k mírnému zlepšení. Proměnná OA tedy zůstane vyřazena z modelu.

Tabulka 13: Klasifikační matice 2

		% správně	Klasifikace modelu	
			0	1
Skutečnost	0	90.9	30	3
	1	84.8	5	28
Celkem		87.8	35	31

Zdroj: výstup z programu Statistica


Tabulka standardizovaných koeficientů pod odstavcem i nadále přisuzuje největší významnost proměnným ROA a CZ. Proměnná PL (pohotová likvidita) dosahuje nejnižší hodnoty standardizovaného koeficientu, proto bude podrobněji zkoumána.

Tabulka 14: Standardizované koeficienty 2

Proměnná	Kořen
ROA	-0.869
CZ	0.663
P1	-0.322
LzPCF	0.229
PL	0.044
P2	0.352

Zdroj: výstup z programu Statistica

Krabicový graf (obrázek č. 4) proměnné PL vykazuje lepší diskriminační potenciál, než tomu bylo u proměnné OA. Hodnoty kategorizované podle skupin se překrývají, ale v menší míře než u OA.



Obrázek 4: Krabicový graf z proměnné PL

Zdroj: výstup z programu Statistica

Aritmetické průměry proměnné PL podle skupin vykazují poměrně výrazný rozdíl. Problémem je zkreslení kvůli odlehlým a extrémním hodnotám, proto je vhodnější sledovat medián kategorizovaný podle skupin. Medián již mezi skupinami nevykazuje tak významné rozdíly jako průměr, přesto jde o významnější diskriminační kritérium.

Tabulka 15: Průměry a mediány proměnné PL

Skupina	Průměr	Medián
0	2.05	0.90
1	0.67	0.45

Zdroj: výstup z programu Statistica

Dále prověříme, zda klasifikační přesnost zůstane shodná i po vyřazení proměnné PL. V tabulce níže pozorujeme stejnou klasifikační úspěšnost i po vyřazení proměnné PL. V dalším postupu je PL z modelu vyřazena. Po vyřazení proměnných PL a OA dosahuje úspěšnost klasifikace na testovaném souboru 87,8 %. Oba druhy chybné klasifikace jsou téměř vyrovnané. Mírně převažuje chybné zařazení podniku z bankrotní skupiny jako bonitního podniku.

Tabulka 16: Klasifikační matice 3

		% správně	Klasifikace modelu	
			0	1
Skutečnost	0	90.9	30	3
	1	84.8	5	28
Celkem		87.8	35	31

Zdroj: výstup z programu Statistica

Tabulka níže zobrazuje standardizované koeficienty 5 zbývajících proměnných seřazených podle velikosti. Mezi proměnnými již není proměnná s velmi nízkým koeficientem. Při pokusu o vyřazení proměnné (LzPCF) s nejnižším standardizovaným koeficientem již došlo ke zhoršení klasifikační přesnosti, proto již neproběhne další redukce proměnných.

Tabulka 17: Standardizované koeficienty 3

Proměnná	Kořen
ROA	-0.876
CZ	0.656
P2	0.358
P1	-0.307
LzPCF	0.225

Zdroj: výstup z programu Statistica

V modelu zůstaly proměnné ROA, CZ, P2, P1 a LzPCF. Na vzorku, který má tato práce k dispozici, byly tyto ukazatele vyhodnoceny jako nejsilnější prediktory úpadku. Rentabilita aktiv (ROA) a Celková zadluženost (CZ) jsou podle standardizovaných koeficientů nejvýznamnější. Poměrové ukazatele ROA a CZ jsou velmi často součástí modelů predikujících selhání podniku (např. Altmanovo Z-Skóre, Beermanova diskriminační funkce (BDF), IN95 a další). Další proměnné v modelu (P2, P1) jsou v tomto, nebo v modifikovaném stavu také používány (např. Altmanovo Z-skóre – P1, P2). Ukazatel LzPCF není příliš rozšířený. Poměrového ukazatele na bázi CF využívá např. Beermanova diskriminační funkce.

4.2 Výsledný model a jeho koeficienty

K sestavení finálního modelu jsou zapotřebí prosté koeficienty, nikoliv standardizované. Tabulka č. 14 znázorňuje prosté koeficienty modelu. Nesmíme opomenout konstantu, se kterou model počítá při výpočtu kanonického skóre.

Tabulka 18: Prosté koeficienty modelu

	Koeficient
ROA	-5.537
CZ	2.175
P1	-0.817
P2	0.651
LzPCF	0.350
Konstanta	-1.895

Zdroj: výstup z programu Statistica

Výsledný model sestavený z tabulky č. 13 je přepsán do formy rovnice, ze které lze vypočítat diskriminační skóre. Diskriminační skóre slouží k zařazení jednotky do skupiny. Konkrétní hranice pro zařazení jsou popsány níže. Samotné velikosti prostých koeficientů nelze objektivně interpretovat. K tomuto účelu slouží standardizované koeficienty. Model vypadá následovně:

$$DS = -1,895 - 5,537 * ROA + 2,175 * CZ - 0,817 * P1 + 0,651 * P2 + 0,350 * LzPCF, \quad (27)$$

kde

DS – Diskriminační skóre,

$$\text{Likvidita z provozního CF (LzPCF)} = \frac{\text{CF z provozní činnosti}}{\text{Krátkodobé cizí zdroje}},$$

$$\text{Celková zadluženost (CZ)} = \frac{\text{Cizí zdroje}}{\text{Aktiva celkem}},$$

$$\text{Výnosnost celkových aktiv (ROA)} = \frac{\text{Čistý zisk (EAT)}}{\text{Aktiva celkem}},$$

$$P1 = \frac{\text{Oběžná aktiva} - \text{Krátkodobé závazky} - \text{Bankovní úvěry}}{\text{Aktiva celkem}},$$

$$P2 = \frac{\text{Nerozdělený zisk z minulých let} + \text{HV B. O}}{\text{Aktiva celkem}}.$$

Hranice modelu pro výpočet klasifikační matice je při použití kanonické diskriminační analýzy a při vyrovnané četnosti případů ve skupinách hodnota 0. Následující tabulka uvádí průměrná DS podle skupin. Z tabulky vyplývá, že pokud analyzovaný podnik dosáhne hodnoty v intervalu $(-\infty; 0)$, pak je zařazen do bonitní skupiny (skup. 0). Pokud naopak dosáhne hodnoty v intervalu $(0; \infty)$, tak dojde k zařazení do skupiny bankrotní (skup. 1). V případě

hodnoty $DS = 0$ nelze o zařazení jednotky jednoznačně rozhodnout, jedná se o stejný princip jako šedá zóna. Nastavení tzv. šedé zóny je v práci dále rozvedeno.

Konstrukce hranice pro klasifikaci vychází z tabulky níže a je definována následovně (viz také vztah (7) [11]):

$$\text{Prahový bod } (C) = \frac{\bar{Z}_1 + \bar{Z}_2}{2}, \quad (28)$$

kde:

\bar{Z}_1, \bar{Z}_2 – Průměry kanonických proměnných,

C – Prahový bod (kritická hodnota diskriminačního skóre).

Tabulka 19: Průměry kanonických proměnných

Skupina	Průměry kanonických proměnných
0	-1.050
1	1.050

Zdroj: výstup z programu Statistica

4.3 Testování úspěšnosti modelu před zavedením šedé zóny

Výsledný model uvedený v podkapitole 4.2 byl vytvořen pouze z části dat, která byla k dispozici. Tento postup byl zvolen, aby bylo možné otestovat přesnost klasifikace na nezávislém vzorku dat, jenž nebyl použit pro tvorbu modelu. Výsledky provedení testu klasifikační přesnosti jsou k vidění v tabulce níže.

Při ověření klasifikační přesnosti na testovacím vzorku vyšla najevo výraznější chybovost modelu, ale pouze u podniků v úpadku (skupina 1). Tudíž model často klasifikoval podniky v úpadku do bonitní skupiny (skupina 0). V případě klasifikace bonitních podniků model chyboval pouze u jednoho případu.

Tabulka 20: Klasifikační přesnost na testovacím vzorku


		% správně	Klasifikace modelu	
			0	1
Skutečnost	0	96.88	31	1
	1	65.63	11	21
Celkem		81.25	42	22

Zdroj: výstup z programu Statistica

Pro názornost je použit bodový graf (obrázek č. 5), který znázorňuje dosažené hodnoty skóre případů v testovacím vzorku (osa Y). Barevně je pak rozlišena skupina bonitních i bankrotních

podniků. Hodnota 0 na ose Y je zvýrazněna černou čarou a představuje výchozí hranici modelu pro klasifikaci. Případy pod černou čarou byly klasifikovány jako bonitní a nad ní pak jako bankrotní.

Informace z grafu (obrázek 5) naznačují, že klasifikační hranice by měla být posunuta směrem dolů, tedy potenciálně více chyb typu klasifikace bonitního podniku jako bankrotního, ale méně chyb typu klasifikace bankrotního podniku jako bonitního. Toho by mělo být dosaženo zavedením šedé zóny v následující podkapitole.



Obrázek 5: Bodový graf dosaženého skóre podle skupin (testovací soubor dat)

Zdroj:vlastní zpracování (MS Excel)

4.4 Zavedení šedé zóny a klasifikačních hranic

Hranice pro klasifikaci do bankrotní, či bonitní skupiny nebývá ve zkoumaných modelech určena pouze jednou hodnotou, ale dochází k vytvoření šedých zón. Pokud hodnota klasifikačního kritéria dosáhne hodnoty uvnitř intervalu šedé zóny, podnik není klasifikován ani do jedné skupiny. Při tvorbě intervalu šedé zóny je nutné zkoumat procento případů zařazených do šedé zóny. Velký počet případů v šedé zóně degraduje celý model.

V modelu, jímž se tato práce zabývá bude vytvořena šedá zóna z dat celého dostupného souboru. Konkrétní interval šedé zóny bude vytvořen na základě vhodné kombinace klasifikační přesnosti, počtu podniků zařazených do šedé zóny a úsudku autora.


Tabulka níže zobrazuje klasifikační hranice pro hodnoty diskriminačního skóre. Pro hodnoty od minus nekonečna do -0,5 je podnik klasifikován do bonitní skupiny. Pásmo šedé zóny se nachází v intervalu od -0,5 do 0,1. Hodnoty dosahující více než 0,1 DS model hodnotí jako bankrotní (podniky ohrožené úpadkem).

Tabulka 21: Klasifikační hranice modelu

Skupina	Interval
Bonitní	$(-\infty; -0,5)$
Šedá zóna	$(-0,5; 0,1)$
Bankrotní	$(0,1; \infty)$

Zdroj: vlastní zpracování

Šedá zóna je na obrázku níže vymezena orientačně tmavě šedými čarami v intervalu od -0,5 do 0,1 hodnoty DS (osa Y). Zóna byla zkonstruována od hodnoty -0,2 a to přičtením a odečtením hodnoty 0,3. Rozsah šedé zóny je tedy 0,6 diskriminačního skóre. Tyto hodnoty byly stanoveny na základě dosahované úspěšnosti klasifikace a podílu případů zařazených do šedé zóny.



Obrázek 6: Bodový graf a zavedení šedé zóny (celý soubor dat)

Zdroj: vlastní zpracování (MS Excel)

Podniky zařazené do šedé zóny je možné interpretovat jako do jisté míry ohrožené úpadkem, jelikož čím vyšší je dosažená úroveň diskriminačního skóre, tím se také zvyšuje pravděpodobnost úpadku. Pro analytika je doporučováno podrobit podniky zařazené v šedé zóně bližšímu zkoumání.

4.5 Úspěšnost klasifikace vytvořeného modelu

Nejprve je provedena analýza úspěšnosti klasifikace na vzorku, jenž byl použit pro tvorbu modelu. Následuje analýza klasifikace na testovacím vzorku. V závěru podkapitoly se zaměříme na celkovou úspěšnost klasifikace na celém souboru dat.

V klasifikační tabulce níže pozorujeme klasifikační přesnost modelu na souboru dat, **ze kterého byl vytvořen model**. Celkově dosažená přesnost klasifikace dosahuje 90,74 %. Počty chyb dle typu jsou téměř shodné.

Tabulka 22: Klasifikační matice ze souboru dat použitých pro tvorbu modelu

Vzorek pro tvorbu modelu		% správně	Klasifikace modelu	
			0	1
Skutečnost	0	88.89	24	3
	1	92.59	2	25
Celkem		90.74	26	28

Zdroj: výstup z programu Statistica

Struktura podniků zařazených do šedé zóny je vyrovnaná. Do šedé zóny bylo zařazeno 10 případů z 66, vyjádřeno procentuálně - 15,2 %.

Tabulka 23: Případy v šedé zóně (vzorek užitý pro vytvoření modelu)

Skupina	Počet případů v šedé zóně	% ze všech případů
Bonitní	5	15.2
Bankrotní	5	15.2
Celkem	10	15.2

Zdroj: vlastní zpracování

V klasifikační tabulce níže vytvořené z dat, která **nevstoupila do tvorby modelu**, je celková klasifikační úspěšnost 90,57 %. S větší přesností byly správně zařazeny bonitní podniky (skupina 0 – úspěšnost 96,43 %). Méně přesné již bylo správné zařazení bankrotních podniků (skupina 1 – úspěšnost 84 %). Tabulka nezahrnuje případy zařazené do šedé zóny.

Tabulka 24: Klasifikační matice z testovacího vzorku dat

Testovací vzorek		% správně	Klasifikace modelu	
			0	1
Skutečnost	0	96.43	27	1
	1	84.00	4	21
Celkem		90,57	31	22

Zdroj: výstup z programu Statistica

Následující tabulka znázorňuje případy z testovacího vzorku zařazené do šedé zóny. Celkově v šedé zóně skončilo 11 případů ze 64, což je 17,2 %. V šedé zóně převažuje 7 podniků z bankrotní skupiny oproti 4 z bonitní skupiny.

Tabulka 25: Případy v šedé zóně (testovací vzorek)

Skupina	Počet případů v šedé zóně	% ze všech případů
Bonitní	4	12.5
Bankrotní	7	21.9
Celkem	11	17.2

Zdroj: vlastní zpracování

Tabulka níže popisuje výsledek klasifikace **celého souboru dat** (testovací i soubor, na němž byl model vytvářen – celkem 130 podniků) po zavedení šedé zóny. Správnost klasifikace podle jednotlivých skupin je 92,86 % pro bonitní podniky a 88,68 % pro bankrotní podniky. Celková úspěšnost podniků **nezařazených v šedé zóně** je 90,83 %.

Tabulka 26: Klasifikační matice celého souboru

		% správně	Klasifikace modelu	
			0	1
Skutečnost	0	92.86 %	52	4
	1	88.68 %	6	47
Celkem		90.83 %	58	51

Zdroj: výstup z programu Statistica

Důležitým faktorem pro hodnocení modelu je také relativní četnost případů v šedé zóně, což popisuje tabulka níže. V případě vytvořeného modelu šedá zóna zahrnuje 16,2 % případů. 2/3 podniků v šedé zóně tvoří bankrotní podniky a 1/3 podniky bonitní. Lze tedy předpokládat, že pokud dojde k využití modelu na jiný vzorek podniků, budou podniky zařazené v šedé zóně s větší mírou pravděpodobnosti ohrožené úpadkem. Tento předpoklad je však nutné v budoucnu ověřit.

Tabulka 27: Počty případů v šedé zóně

Skupina	Počet případů v šedé zóně	% ze všech případů
Bonitní	7	10.8 %
Bankrotní	14	21.5 %
Celkem	21	16.2 %

Zdroj: vlastní zpracování

5 SROVNÁNÍ VÝSLEDKŮ KLASIFIKACE S VYBRANÝMI MODELÝ

Kapitola se zabývá srovnáním vytvořeného modelu a vybraných modelů zaměřených na predikci bankrotu. Účelem této kapitoly je zjistit, jak si stojí vytvořený model ve srovnání se zavedenými modely.

Při tvorbě modelu bylo dbáno na náhodnost výběru vzorku, přesto je nutné si uvědomit, že koeficienty modelu byly sestaveny z části dostupných dat. Následovalo určení hraničních pásem a šedé zóny, kde při optimalizaci bylo přihlédnuto ke struktuře dosahovaného skóre v celém souboru. Z toho vyplývá, že model by měl být úspěšný při klasifikaci tohoto souboru dat, ale při výběru jiného vzorku dat může být dosažená úspěšnost odlišná.

Vytvořený model (VM) pochází z účetních dat podniků ve zpracovatelském průmyslu v ČR navíc omezených velikostí aktiv. Ideální využití modelu je tedy poměrně specifické. Závěry, které budou následně popsány je nutné dále otestovat na jiném vzorku dat podniků ve zpracovatelském průmyslu ČR.

Srovnání úspěšnosti bude provedeno mezi vybranými modely uvedenými ve 2. kapitole a to konkrétně: Altmanovým Z' skóre, Altmanovým Z'' skóre, Modifikovaným Tafflerovým model, Beermanovou diskriminační funkcí (BDF) a vytvořeným modelem (VM).

Klasickým způsobem hodnotí úspěšnost klasifikace tabulka pod tímto odstavcem. Procentuální hodnota ve sloupci „Klasifikační úspěšnost“ je vypočtena podílem správně zařazených podniků a celkového počtu klasifikovaných případů bez případů, jež jsou v šedé zóně. Nejlepší dosažené výsledky v rámci sloupců jsou barevně škálovány od zelené (nejlepší výsledky) až po červenou (nejhorší výsledky). Nejvíce správně zařazených případů si připsal model vytvořený v této práci, ale také Altmanovo Z'' skóre a model IN05. Nejvyšší hodnoty klasifikační přesnosti dosáhl vytvořený model s přesností 90,83 %, těsně za ním pak Altmanovo Z' skóre s přesností 90,43 %, poté IN05 s 85,34 %, dále Z'' model s 84,62% úspěšností, Tafflerův model dosáhl úspěšnosti 73,11 % a nejhůře klasifikoval model Beermanovy diskriminační funkce s úspěšností pouze 62,30 %. V další části práce již nebude model BDF analyzován, kvůli neuspokojivé klasifikační úspěšnosti a také z toho důvodu, že na rozdíl od ostatních modelů neobsahuje šedou zónu.

Tabulka 28: Klasifikační úspěšnost vybraných modelů

Model	Správně	Chyba	Klasifikační úspěšnost
Altmanovo Z' skóre	85	9	90.43 %
Altmanovo Z'' skóre	99	18	84.62 %
Tafflerův model	87	32	73.11 %
Beermanova diskř. Funkce (BDF)	81	49	62.30 %
IN05	99	17	85.34 %
Vytvořený model (VM)	99	10	90.83 %

Zdroj: vlastní zpracování

Výše zmíněný způsob srovnání není příliš objektivní, protože nezahrnuje případy zařazené v šedé zóně. To vede zpravidla k vyšší úspěšnosti modelů se zavedenou širší šedou zónou.

V tabulce níže pozorujeme, kolik případů bylo zařazeno do šedé zóny, a navíc také součet případů v šedé zóně a chyb. Nejvíce případů do šedé zóny zařadilo Altmanovo Z' skóre, druhý model nejčastěji zahrnující případy do šedé zóny byl model VM. Nejvyššího **podílu případů zařazených chybně, nebo do šedé zóny** dosáhly modely Altmanovo Z' skóre 34,62 % a Tafflerův model 33,08 %. Naopak nejlepšího výsledku, tedy nejnižšího podílu dosáhly modely Altmanovo Z'', IN05 a VM.

Tabulka 29: Analýza chyb a případů v šedé zóně

Model	Šedá zóna	Šedá zóna + chyby	Procento ŠZ + chyby
Altmanovo Z' skóre	36	45	34.62%
Altmanovo Z'' skóre	13	31	23.85%
Tafflerův model	11	43	33.08%
IN05	14	31	23.85%
Vytvořený model (VM)	21	31	23.85%

Zdroj: vlastní zpracování

Další pohled na úspěšnost klasifikace nabízí tabulka níže. Tabulka **analyzuje počet správně zařazených případů v kontextu celkového počtu testovaných subjektů**. Ve své podstatě podíl správně zařazených jednotek a celkového počtu případů zhoršuje úspěšnost modelů se zavedenou šedou zónou, jelikož zařazení do šedé zóny je v rámci ukazatele počítáno mezi chyby. Oproti předchozímu způsobu hodnocení se výrazně snížila úspěšnost Altmanova Z' skóre, a to kvůli vysokému počtu případů v šedé zóně. Nejlépe se pak shodně s úspěšností 76,15 % jeví modely Altmanovo Z'', IN05 a model vytvořený v této práci.

Tabulka 30: Správná klasifikace z celkového počtu případů

Model	Šedá zóna + chyby	Správně	Správně/Celkem
Altmanovo Z' skóre	45	85	65.38 %
Altmanovo Z'' skóre	31	99	76.15 %
Tafflerův model	43	87	66.92 %
IN05	31	99	76.15 %
Vytvořený model (VM)	31	99	76.15 %

Zdroj: vlastní zpracování

Níže uvedená tabulka představuje objektivnější způsob zohlednění šedých zón do výpočtu úspěšnosti klasifikace. V tabulce uvedený ukazatel vychází z předpokladu teoretické náhodné správné klasifikace případů v šedé zóně, která v případě 2 skupin dosahuje 50 %. Konstrukce ukazatele je následovná:

$$UK = \frac{(S + \frac{1}{2} * \check{S}Z)}{CP}, \quad (29)$$

kde:

S – počet správně klasifikovaných případů,

$\check{S}Z$ – počet případů zařazených v šedé zóně,

CP – celkový počet případů,

UK – úspěšnost klasifikace při zohlednění šedé zóny.

Nejlepší úspěšnosti dosáhly v upraveném kritériu modely VM, Altmanovo Z'', IN05 a Altmanovo Z'. Hůře pak klasifikoval Tafflerův. Tento způsob zhodnocení úspěšnosti modelů se zavedenou šedou zónou se zdá být neobjektivnější.

Tabulka 31: Zohlednění šedé zóny do přesnosti klasifikace

Model	Správně	Šedá zóna	Chyba	% úspěšnost při zohlednění ŠZ (UK)
Altmanovo Z' skóre	85	36	9	79.23%
Altmanovo Z'' skóre	99	13	18	81.15%
Tafflerův model	87	11	32	71.15%
IN05	99	14	17	81.54%
Vytvořený model (VM)	99	21	10	84.23%

Zdroj: vlastní zpracování

Při hodnocení úspěšnosti klasifikace není srovnávána pouze úspěšnost správné klasifikace. Analyzována je také úspěšnost **klasifikace podle typu chyby**. V tabulce č. 2 v první kapitole jsou zobrazeny dva možné typy chyb. Chyba klasifikace 1 (CHK 1) vyjadřuje situaci, kdy model zařadí do bonitní skupiny 0 podnik, který je ve skutečnosti podnikem z bankrotní skupiny 1. Chyba klasifikace 0 (CHK 0) charakterizuje chybnou klasifikaci, kdy je bonitní podnik zařazen do bankrotní skupiny.

Konkrétní rozdělení chyb podle typu a modelu na celém vzorku dat (bez případů v šedé zóně) vyjadřuje tabulka níže. U obou **Altmanových modelů** docházelo k chybám klasifikace 1 i 0 ve stejném poměru. Častěji docházelo k CHK 0 v poměru dva ku jedné. Altmanův model Z' chyboval nejméně ze všech modelů v klasifikaci podniků spějícím k bankrotu. Struktura chyb u **Tafflerova** modelu zaslouží vyšší pozornosti, jelikož převažují výrazně CHK 1 nad CHK 0. Pravděpodobně by bylo dosaženo lepší úspěšnosti klasifikace při drobné úpravě klasifikačních hranic, nebo koeficientů. U modelu **IN05** převažují CHK 0. Společně s Altmanovým Z' dosáhl nejnižší chybovosti CHK 1. Struktura chyb v modelu **VM** je téměř rovnoměrná s mírně převažujícími CHK 1 nad CHK 0.

Tabulka 32: Chyby v klasifikaci podle typu

Model	Chyba klasifikace 1				Chyba klasifikace 0			
	Počet	% z celkem	% bez šedé zóny	% typu chyby	Počet	% z celkem	% bez šedé zóny	% typu chyby
Altmanovo Z' skóre	3	2.31 %	3.19%	33.33 %	6	4.62 %	6.38 %	66.67 %
Altmanovo Z'' skóre	6	4.62 %	5.13%	33.33 %	12	9.23 %	10.26 %	66.67 %
Tafflerův model	29	22.31 %	24.37%	90.63 %	3	2.31 %	2.52 %	9.38 %
IN05	4	3.08 %	3.45%	23.53 %	13	10.00 %	11.21 %	76.47 %
Vytvořený model (VM)	6	4.62 %	5.50%	60.00 %	4	3.08 %	3.67 %	40.00 %

Zdroj: vlastní zpracování

V této kapitole bylo představeno několik pohledů na hodnocení úspěšnosti modelů predikujících bankrot. Nejpoužívanější přístup hodnotící pouze počet chybných klasifikací bez ohledu na počet případů v šedé zóně vyhodnotil jako nejúspěšnější model vytvořený v této práci (90,83 %). S malým odstupem v úspěšnosti pak skončily modely Altmanovo Z' (90,43 %), model IN05 (85,34) a Altmanovo Z'' (84,62 %). Tento výsledek byl očekáván, protože Altmanův model je považován za stabilní a byl vytvořen z obdobného vzorku podniků v prostředí USA. Od modelu IN05 byla také očekávána přesná klasifikace hlavně z důvodu původu a aktuálnosti modelu. Model IN05 byl vytvořen v podmínkách ČR navíc v poměrně nedávné době.

V kapitole byly použity způsoby, které se snaží zohlednit zařazování případů do šedých zón. Z této analýzy vzešly výsledky obdobné výsledkům zmíněným výše, ale k určitým změnám v pořadí došlo kvůli nadměrnému přiřazování případů do šedé zóny. Nejvíce tento přístup ovlivnil Altmanovo Z' skóre kvůli největšímu počtu případů v šedé zóně.

Důležité poznatky přinesla analýza typu chyb, kde jsou zřetelné rozdíly mezi klasifikací vybraných modelů. U Tafflerova modelu byla zjištěna vysoká přesnost při určení bonitních podniků, ale u klasifikace bankrotních podniků byl model nejméně úspěšný.

ZÁVĚR

Cílem této práce bylo sestavení modelu vytvořeného na základě diskriminační analýzy. Pro tvorbu modelu byla vybrána data ze zpracovatelského průmyslu v ČR s omezenou velikostí aktiv, dostupnými daty bez chybějících klíčových údajů a dalšími charakteristikami uvedenými ve 3. kapitole. Dále bylo přesně definováno zařazení podniků do jednotlivých skupin. V případě bankrotních dle platné legislativy a v případě podniků v bonitní skupiny bylo pro zajištění objektivitu výběru využito generátoru náhodných čísel.

V databázi Magnus společnosti Bisnode byly vyhledány podniky v úpadku splňující podmínky, jichž bylo nalezeno v databázi 65. Následně bylo vybráno 65 podniků splňujících podmínky pro zařazení do bonitní skupiny. Soubor byl dále rozdělen na 2 množiny, kdy jedna skupina sloužila k vytvoření modelu a druhá pro následné testování. Model byl sestaven ze vzorku 33 bankrotních a stejného počtu bonitních podniků.

Na základě dostupných informací z literárních pramenů, stávajících osvědčených modelů a úsudku autora došlo k výběru proměnných, které vstoupily do tvorby modelu. V rámci snahy o zjednodušení modelu a maximalizaci klasifikační úspěšnosti tvořeného modelu byly pak dvě proměnné vyřazeny. Jednalo se o obrat aktiv a pohotovou likviditu. Důvodem pro vyřazení těchto proměnných byla jejich nedostatečná schopnost přispět k rozlišení mezi podniky v bankrotní a bonitní skupině, proto pominul důvod ponechání proměnných v modelu. Klasifikační přesnost modelu po vyřazení zmíněných proměnných se buď mírně zlepšila, nebo se nezhoršila, což podpořilo oprávněnost vyjmutí proměnných.

Ve výsledném modelu tedy nakonec zůstalo 5 proměnných: ROA (při použití EAT), Celková zadluženost (CZ), Likvidita z provozního CF (LzPCF), proměnná P1 a P2. Největší vliv pro tvorbu skóre dle standardizovaných koeficientů, měly proměnné ROA a CZ.

Hranice pro určení klasifikace byla upravena přidáním šedé zóny. Šedá zóna byla sestrojena na základě změn přesnosti klasifikace a podílu případů zařazených v šedé zóně. Do šedé zóny se po jejím zavedení dostalo 21 případů z celkových 130, což činí 16,2 %. Celková přesnost klasifikace (bez zohlednění případů v šedé zóně) na vybraném vzorku dosáhla 90,83 %. Správná klasifikace podniků v bankrotní skupině dosáhla hodnoty 88,68 %. Podnikům v bonitní skupině model přiřadil správně skupinu v 92,86 % počtu případů.

Poslední kapitola se zabývala srovnáním úspěšnosti klasifikace mezi sestaveným modelem a vybranými modely na dostupném vzorku dat. Konkrétně byly vypočteny přesnosti klasifikace pro Altmanovy modely Z' a Z'' , modifikovaný Tafflerův index, Bermanovu diskriminační

funkci a index IN05. Pro objektivnější posouzení kvality modelů došlo k zavedení různých kritérií úspěšnosti modelů.

Nejvyššího počtu správně klasifikovaných případů dosáhly modely Altmanovo Z'' , IN05 a v práci vytvořený model (VM). Zajímavostí je, že všechny tři modely správně klasifikovaly 99 případů ze 130. Rozdílně pak zařadily případy do šedých zón, přičemž modely Z'' a IN05 vykazaly téměř stejnou strukturu chyb a případů v šedé zóně.

Nejméně chyboval model Altmanovo Z' přičemž nesprávně klasifikoval pouze 9 případů. Následoval model VM s 10 chybami. Problémem u modelu Z' je především nejvyšší počet případů zařazených v šedé zóně. Pro lepší srovnatelnost kvality modelů byl zaveden ukazatel, který 50 % podniků v šedé zóně počítá mezi chyby. Z pohledu zavedeného ukazatele kvality modelu vzešel jako nejúspěšnější model VM, ale srovnatelně dobrých výsledků dosáhly modely Z'' , Z' , IN 05. O poznání hůře si pak vedl Tafflerův model.

Hlavním cílem práce bylo vytvoření modelu predikujícího bankrot (úpadek) pomocí diskriminační analýzy. Tento cíl byl splněn a kvalita modelu se na dostupném vzorku zdá být uspokojivá. Tento závěr by bylo vhodné ověřit na jiných vzorcích podniků v ČR, jelikož srovnání se zavedenými modely bylo testováno pouze na vzorku dat, ze kterého byl model částečně vytvořen.

POUŽITÁ LITERATURA

- [1] AGARWAL, Vineet a Richard J. TAFFLER. Twenty-five years of the Taffler z-score model: Does it really have predictive ability? *Accounting and Business Research* [online]. 2007, **37**(4), 285-300 [cit. 2017-06-25]. DOI: 10.1080/00014788.2007.9663313. ISSN:00014788
Dostupné z: <http://www.tandfonline.com/doi/abs/10.1080/00014788.2007.9663313>
- [2] ALTMAN, Edward I. FINANCIAL RATIOS, DISCRIMINANT ANALYSIS AND THE PREDICTION OF CORPORATE BANKRUPTCY. *The Journal of Finance* [online]. 1968, **23**(4), 589-609 [cit. 2017-06-25]. DOI: 10.1111/j.1540-6261.1968.tb00843.x. ISSN 00221082. Dostupné z: <http://doi.wiley.com/10.1111/j.1540-6261.1968.tb00843.x>
- [3] ALTMAN, Edward I., Małgorzata IWANICZ-DROZDOWSKA, Erkki K. LAITINEN a Arto SUVAS. Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z- Score Model. *Journal of International Financial Management & Accounting* [online]. 2017, **28**(2), 131-171 [cit. 2017-06-25]. DOI:10.1111/jifm.12053. ISSN:09541314.
Dostupné z: <http://doi.wiley.com/10.1111/jifm.12053>
- [4] BLAHA, Zdenek Sid a Irena JINDŘICHOVSKÁ. *Jak posoudit finanční zdraví firmy*. 3., rozš. vyd. Praha: Management Press, 2006. ISBN 8072611453.
- [5] Český statistický úřad. Vysvětlivky CZ-NACE. In: Český statistický úřad [online]. [cit. 2017-06-21]. Dostupné z: https://www.czso.cz/documents/10180/23174387/vysvetlivky_cz_nace.pdf/f530ebeb-f949-40c7-a27d-f8888503d791?version=1.0.
- [6] HEBÁK, Petr. *Vícerozměrné statistické metody*. 2., přeprac. vyd. Praha: Informatorium, 2007. ISBN 9788073330569.
- [7] CHOI, Frederick D. S. *International finance and accounting handbook*. 3rd ed. Hoboken, N.J.: J. Wiley, c2003. ISBN 9780471229216.
- [8] KALOUDA, František. *Finanční analýza a řízení podniku*. 2. rozšířené vydání. Plzeň: Vydavatelství a nakladatelství Aleš Čeněk, 2016. ISBN 9788073805913.
- [9] KNÁPKOVÁ, Adriana, Drahomíra PAVELKOVÁ a Karel ŠTEKER. *Finanční analýza: komplexní průvodce s příklady*. 2., rozš. vyd. Praha: Grada, 2013. ISBN 9788024744568.

- [10] KUBĚNKA, Michal. *Finanční stabilita podniku a její indikátory*. Pardubice: Univerzita Pardubice, Fakulta ekonomicko-správní, 2015. ISBN 9788073958909.
- [11] MELOUN, Milan a Jiří MILITKÝ. *Interaktivní statistická analýza dat*. Praha: Karolinum, 2012. ISBN 9788024621739.
- [12] STANKOVIČOVÁ, Iveta a Mária VOJTKOVÁ. *Viacrozmerné štatistické metódy s aplikáciami*. Bratislava: IURA Edition, 2007. Ekonómia. ISBN 9788080781521.
- [13] SYNEK, Miloslav a Eva KISLINGEROVÁ. *Podniková ekonomika*. 6., přeprac. a dopl. vyd. V Praze: C.H. Beck, 2015. Beckovy ekonomické učebnice. ISBN 9788074002748.
- [14] VALACH, Josef. *Finanční řízení podniku*. 2. aktualiz. a rozš. vyd. Praha: Ekopress, 1999. ISBN 8086119211.
- [15] VOCHOZKA, Marek. *Metody komplexního hodnocení podniku*. Praha: Grada, 2011. Finanční řízení. ISBN 9788024736471.
- [16] Zákon č. 182/2006 Sb., *Zákon o úpadku a způsobech jeho řešení (insolvenční zákon)*.

SEZNAM PŘÍLOH

Příloha A Analyzovaný vzorek dat

Příloha A: Analyzovaný vzorek dat

ČástI	IČ PODNIKU	ROK ÚČ. DAT	ROK ÚPADKU	SKUP.	TEST. S.	AKTIVA CELKEM	ROA	CZ	P1	P2	OA	LzPCF	PL
1	14869799	2014		0	0	74681	-0.01178	0.795236	-0.22991	-0.20187	1.928469	0.025729	0.199347
2	479730	2014		0		97503	0.074152	0.675743	0.404398	0.179328	1.610853	0.017432	1.227009
3	45534225	2014		0	0	98136	0.044622	0.68187	-0.00201	-0.42477	1.664588	0.035124	0.31699
4	60193034	2014		0		153714	0.048057	0.186092	0.442465	0.199643	1.121752	-0.16502	1.72719
5	18248586	2014		0	0	159662	0.036064	0.980979	-0.36403	-0.19719	0.880773	0.100633	0.238733
6	60468734	2014		0		160097	-0.00172	0.024154	0.104737	-0.01284	0.052012	0.3194	4.381565
7	25858947	2014		0	0	170846	0.101624	0.287586	0.425278	0.176838	2.752391	0.630952	1.917644
8	24242438	2014		0		178531	0.239062	0.199366	0.286533	0.170223	1.079672	-2.89943	1.603886
9	25748483	2014		0	0	198612	0.00653	0.431741	0.088952	0.006772	1.401522	0.598024	1.005934
10	26276151	2014		0		217632	0.218364	0.564127	0.141781	0.430819	1.788822	0.275346	1.403081
11	47545259	2014		0	0	222817	-0.01335	0.639619	0.433553	0.175561	2.419245	-1.17668	1.400219
12	25560280	2014		0		226968	-0.50413	1.108139	0.346511	-1.22568	0.525109	0.912101	0.736561
13	49788221	2014		0	0	247122	0.014815	0.602407	0.113656	0.142464	1.467546	0.022136	0.786658
14	26183960	2014		0		251697	0.082313	0.192489	0.757876	0.519291	1.792552	0.634673	3.307096
15	49711989	2014		0	0	264886	0.0839	0.283477	0.169465	0.141291	1.011847	0.788547	0.726906
16	60731796	2014		0		286433	0.043026	0.70502	-0.40867	0.274874	1.175915	0.203631	0.486076
17	47676663	2014		0	0	287385	0.057703	0.446238	-0.02052	0.24684	1.350707	0.532704	1.154074
18	63219514	2014		0		295389	0.067724	0.630365	0.043857	0.207303	0.762621	0.505968	0.727909
19	25337408	2014		0	0	296864	0.032796	0.39478	0.017328	0.484892	0.276123	0.583935	0.520423
20	25732153	2014		0		305220	-0.00048	0.06821	0.873848	0.84658	0.391888	3.065546	16.88149
21	60193247	2014		0	0	319629	0.048832	0.381467	0.249136	0.193305	0.46549	0.121787	0.340319
22	62916408	2014		0		325697	0.112577	0.27949	0.601025	-0.09465	1.99078	0.177278	3.123998
23	24124664	2014		0	0	342415	0.030589	0.544483	-0.01067	0.009766	1.240501	0.344742	0.686474
24	40612724	2014		0		343058	0.026101	0.248812	0.399352	0.359304	1.011275	0.755927	2.398531

Část2	IČ PODNIKU	ROK ÚČ. DAT	ROK ÚPADKU	SKUP.	TEST. S.	AKTIVA CELKEM	ROA	CZ	P1	P2	OA	LzPCF	PL
25	47672153	2014		0	0	354985	0.085854	0.596056	0.23317	0.302689	1.007862	0.130484	0.860121
26	46504508	2014		0		361211	0.116699	0.092547	0.610244	0.907079	0.603799	0.792583	5.787694
27	44568703	2014		0	0	369229	0.009574	0.027205	0.879993	0.823001	0.761037	-1.27247	18.86869
28	49612212	2014		0		370773	0.208311	0.366305	0.114116	0.432612	1.60622	0.668553	1.236612
29	44016107	2014		0	0	374115	0.170421	0.418601	0.56824	0.412705	1.287192	0.20712	1.904578
30	49790331	2014		0		378998	0.131193	0.09609	0.503071	0.697756	0.949303	1.961854	5.714762
31	60108703	2014		0	0	384270	0.026265	0.343678	0.04221	0.194212	1.993796	0.490906	1.042819
32	00659487	2014		0		387741	0.046031	0.682069	0.14773	0.104784	1.323239	0.303299	0.878723
33	46347909	2014		0	0	391648	0.14462	0.165176	0.533213	0.179442	1.172627	1.018366	2.038817
34	15789578	2014		0		403561	0.105573	0.10364	0.400336	0.722154	1.767819	1.198686	1.998662
35	27284735	2014		0		445888	-0.08065	1.254254	0.069403	-0.27324	0.025964	-3.34311	0.975691
36	15052346	2014		0	0	490396	0.114821	0.465703	0.317335	0.169457	1.202322	0.512702	1.710961
37	25605755	2014		0		496293	0.072598	0.575499	0.020337	0.334355	1.181594	0.403988	0.774877
38	48171514	2014		0	0	530323	0.176013	0.270978	0.302757	0.566689	1.722132	2.191096	1.662505
39	26819210	2014		0		530779	0.465894	0.184342	0.444982	0.715891	1.433045	4.59082	4.034615
40	26729610	2014		0	0	537596	-0.00289	0.80469	-0.361	-0.61791	2.234451	-0.15389	0.295793
41	46882324	2014		0		539190	0.043196	0.281765	0.134253	0.342428	0.828496	0.262408	0.801847
42	63271371	2014		0	0	540456	0.084773	0.224725	0.328567	0.762673	1.474283	1.23939	3.477543
43	26084996	2014		0		546923	0.122333	0.532627	-0.09233	0.004205	1.296793	0.07997	0.46766
44	26765306	2014		0	0	550974	0.106827	0.469683	0.040289	0.153339	1.963975	0.56565	0.813058
45	00658251	2014		0		564381	0.063569	0.110438	0.307822	0.144817	1.400678	2.450458	2.556849
46	48398233	2014		0	0	631896	0.107337	0.08182	0.698792	0.902675	1.530397	0.786238	5.352931
47	49455851	2014		0	0	669450	0.022079	0.454721	-0.06202	0.071093	0.86595	0.130511	0.461004
48	25426583	2014		0		679308	0.260097	0.315899	0.609909	0.675518	1.278707	-0.02616	2.269817
49	25252968	2014		0	0	698474	0.006995	0.812441	-0.03574	0.170379	0.838736	0.580136	0.900408
50	41602471	2014		0		711552	0.03782	0.084157	0.769221	0.889863	0.636978	0.137243	7.449254
51	25935429	2014		0	0	718419	0.269621	0.54639	0.353316	0.425771	1.666913	1.627919	2.026614

Část 3	IČ PODNIKU	ROK ÚČ. DAT	ROK ÚPADKU	SKUP.	TEST. S.	AKTIVA CELKEM	ROA	CZ	P1	P2	OA	LzPCF	PL
52	26151197	2014		0		720760	0.280658	0.732674	0.108	0.064861	3.616759	-0.01539	0.990517
53	27841987	2014		0	0	771456	-0.1093	0.923384	0.359886	-0.39978	0.973008	-0.14722	1.503284
54	45192294	2014		0		822381	-0.02619	0.696053	-0.11558	-0.03936	2.377965	0.039122	0.600368
55	00142492	2014		0	0	860616	0.081343	0.049655	0.62879	0.804668	0.636826	2.714868	11.10119
56	27384098	2014		0		918981	0.05975	0.783381	0.011809	0.159491	2.49376	0.214476	0.469802
57	24822787	2014		0	0	928944	0.040596	0.806489	0.191824	0.053352	5.847371	0.023129	0.412614
58	61504424	2014		0		949236	0.214513	0.538643	0.333493	0.375247	2.368254	0.663476	1.354354
59	27133079	2014		0	0	1173657	0.095552	0.378412	0.513423	0.498894	4.743441	0.259151	2.051383
60	25655809	2014		0		1227966	0.208564	0.096162	0.428124	0.533684	0.835858	3.539314	5.008965
61	60192925	2014		0	0	1377237	-0.02505	0.61455	-0.2424	-0.20813	1.155743	-0.13064	0.415362
62	26954664	2014		0		1415846	0.306761	0.178485	0.263553	0.736605	1.524266	3.549209	2.394218
63	25413783	2014		0	0	1428299	0.016508	0.81218	-0.22309	-0.01528	1.472368	0.042242	0.59598
64	26052377	2014		0		1590986	0.068238	0.284793	0.151581	0.115279	1.39314	0.683459	0.940248
65	26198436	2014		0	0	1630581	0.105781	0.345298	0.131116	-0.0196	1.235336	0.332176	0.810834
66	49240013	2014	2015	1		72678	-1.1321	1.987355	-1.01245	-4.40857	0.522276	0.159099	0.036522
67	25581767	2006	2007	1	1	76047	-0.26029	1.493747	-1.05053	-1.28685	2.560259	-0.2583	0.17389
68	45192154	2013	2014	1		80067	-0.40299	1.275719	-0.942	-2.28916	0.59113	-0.08603	0.238631
69	25467557	2009	2010	1	1	91028	-0.47205	1.041482	-0.19628	-0.68632	3.818814	0.18493	0.452656
70	27150747	2014	2015	1		102140	-0.1459	0.644224	0.123262	0.289789	0.417476	0.108682	0.19515
71	26417936	2011	2012	1	1	106122	-0.04775	0.950519	-0.1146	-0.04682	1.37929	-0.07778	0.386706
72	28781562	2013	2014	1		114129	-0.00042	1.088838	-0.11235	-0.09077	0.002339	0.003396	0.106769
73	27712265	2012	2013	1	1	114372	0.009312	1.20575	-0.24574	-0.22588	5.225247	-0.01497	0.790644
74	26493381	2015	2016	1		134788	-0.23939	1.727305	-0.42976	-2.21902	0.023919	0.019861	0.180559
75	60792523	2004	2005	1	1	150550	-0.37819	0.916745	-0.49677	-2.29394	0.411166	-0.23459	0.047703
76	46708511	2010	2011	1		154165	-0.51114	1.432906	-1.16179	-0.77076	2.40467	0.20081	0.134323
77	25935267	2006	2007	1	1	157683	-0.01091	1.346455	-0.00406	-1.0657	0.019691	0.731587	0.788162
78	26114861	2009	2010	1		186096	-0.83079	2.008657	-1.6346	-1.55842	0.545665	0.049481	0.058146

Část 4	IČ PODNIKU	ROK ÚČ. DAT	ROK ÚPADKU	SKUP.	TEST. S.	AKTIVA CELKEM	ROA	CZ	P1	P2	OA	LzPCF	PL
79	26118394	2008	2009	1	1	195511	-0.03133	0.74516	-0.08495	0.048263	1.987581	0.091474	0.441025
80	47906260	2014	2015	1		195769	-0.02339	0.683356	-0.00042	0.244666	1.458581	0.019995	0.738095
81	62742604	2009	2010	1	1	199929	-0.02915	0.987235	0.005107	0.012204	1.185011	-0.00511	0.765854
82	26325021	2012	2013	1		201367	-0.2278	0.719616	-0.0718	0.066496	0.350226	-0.64708	0.73139
83	60069724	2005	2006	1	1	213079	-0.3283	0.673863	-0.05922	-0.30779	0.830762	0.818793	0.450665
84	14502241	2007	2008	1	1	237532	-0.98281	0.184544	0.529402	-1.44402	1.430797	-0.73758	3.881182
85	60722690	2011	2012	1		239336	-0.38111	0.93426	-0.6309	-0.49665	0.514323	-0.08565	0.114853
86	45275301	2009	2010	1	1	250090	-0.50656	1.490983	-0.88997	-1.84165	0.959427	0.18221	0.369479
87	25256157	2012	2013	1		250533	-0.0517	0.281037	-0.00892	-0.06192	0.371237	0.032636	0.158359
88	49610040	2014	2015	1	1	250684	-0.25327	0.595491	0.375002	0.295013	1.743314	1.04228	1.518464
89	45787425	2011	2012	1		273402	-0.14994	1.002257	-0.36075	-1.59039	0.567242	-0.0258	0.195223
90	00661058	2008	2009	1	1	281029	0.072259	0.7387	-0.25199	0.059332	1.966975	0.63577	0.259143
91	00014010	2013	2014	1		286586	-0.23187	0.848503	-0.48567	-0.8222	0.287579	-0.0213	0.163221
92	49791656	2011	2012	1	1	290790	-0.05818	0.620826	-0.20575	-0.00625	0.550628	-0.01579	0.731702
93	26144999	2007	2008	1		293523	-0.0423	0.801978	-0.39808	-0.10538	0.745107	-0.00456	0.042553
94	45355266	2011	2012	1	1	331409	-0.0449	0.863604	-0.01342	0.069304	0.421002	0.053414	0.883311
95	14892600	2010	2011	1		335226	0.045629	0.64529	-0.17375	0.148199	1.114493	0.450001	0.544039
96	28361806	2011	2012	1	1	340350	-0.08215	1.21688	-0.27431	-0.45781	1.973939	-0.25809	0.425878
97	41197071	2007	2008	1		342683	0.011638	0.743871	0.195239	0.204481	1.017141	0.007882	0.774861
98	27379400	2014	2015	1	1	347517	-0.23413	1.444093	-1.37862	-1.03404	0.297367	-0.03388	0.034924
99	47675942	2010	2011	1		399642	-0.37418	0.638201	-0.11172	-0.28921	1.308263	0.762014	0.395005
100	25508598	2015	2016	1	1	409631	-0.08909	0.69265	-0.3094	-0.09438	1.380074	-0.01541	0.338954
101	25894242	2010	2011	1		411829	0.127466	0.819874	-0.33693	0.177979	1.1761	0.222533	0.391486
102	45475148	2015	2016	1	1	442625	0.007984	0.421565	0.300512	0.604302	0.652046	0.107302	0.566184
103	43001343	2011	2012	1		454998	0.058082	0.308491	0.14213	0.635108	1.832793	0.581605	1.572651
104	27419762	2014	2015	1	1	462532	-0.33485	1.288598	-0.9751	-1.29274	0.217111	-1.25833	0.377298
105	25252721	2011	2012	1		462567	-0.08962	0.408375	-0.11391	-0.25728	0.359407	0.112018	0.176105

Část 5	IČ PODNIKU	ROK ÚČ. DAT	ROK ÚPADKU	SKUP.	TEST. S.	AKTIVA CELKEM	ROA	CZ	P1	P2	OA	LzPCF	PL
106	24148032	2012	2013	1	1	529278	-0.32709	1.440991	-0.55392	-0.44137	2.095702	0.163513	0.559495
107	45022518	2007	2008	1		571017	-0.0081	0.571314	-0.24419	0.170345	1.756293	0.032109	0.063435
108	00473057	2011	2012	1	1	581959	0.074282	0.19618	0.574063	0.408378	0.818315	0.999331	3.768832
109	25124510	2008	2009	1		606004	0.000218	0.596356	-0.19672	-0.00581	0.548777	0.047501	0.396464
110	46962883	2008	2009	1	1	659660	-0.25817	0.74685	-0.37284	-0.50769	0.706479	-0.40871	0.157605
111	27622819	2015	2016	1		705181	-0.40812	1.434819	-0.92741	-0.70001	1.387438	0.058191	0.13976
112	48171468	2006	2007	1	1	707275	-0.03966	0.865669	-0.47263	-1.83395	0.061819	0.452355	0.157813
113	00012351	2007	2008	1		723850	-0.02054	0.895449	-0.17582	-0.24441	2.170669	0.072749	0.348745
114	25100467	2011	2012	1	1	798206	-0.08526	0.934343	-0.77607	-0.50699	0.475955	0.015709	0.127884
115	61858200	2011	2012	1		851406	-0.13431	1.106855	-0.48182	-0.33413	1.034557	-0.07296	0.613515
116	48393223	2007	2008	1	1	851756	-0.165	0.801916	-0.18118	0.059673	1.446163	0.265135	0.465061
117	27931552	2010	2011	1		873513	-0.02121	0.738266	-0.12725	-0.03048	0.714857	0.050805	0.451079
118	25877933	2015	2016	1	1	890859	-0.07668	0.884285	-0.12387	0.002441	0.740043	0.220787	0.518745
119	27768872	2013	2014	1		893859	-0.15639	1.298013	-1.02247	-0.75788	0.167418	0.020303	0.044274
120	26445221	2004	2005	1	1	1011205	0.022877	1.338241	-0.56784	-0.44649	1.224314	0.344705	0.539282
121	27189201	2008	2009	1		1121388	-0.13323	1.107544	-0.36393	-0.28685	0.509915	0.058307	0.202938
122	27167909	2010	2011	1	1	1206419	-0.00588	0.722961	-0.38932	-0.01887	0.973839	0.107301	0.335834
123	26899701	2007	2008	1		1342456	-0.05031	0.97363	-0.94424	-0.06049	0.002231	0.870568	0.027206
124	25532774	2009	2010	1	1	1424917	-0.25464	1.146843	-0.70451	-0.60106	0.789698	-0.74168	0.200259
125	49240005	2014	2015	1		1648625	-0.11841	0.685054	-0.01575	0.025311	0.611664	-0.07803	0.340919
126	27095835	2011	2012	1	1	1693042	-0.03466	0.809883	-0.51243	-0.02575	0.977457	0.372099	0.3609
127	45022526	2012	2013	1		1781134	-0.06308	0.771532	-0.47687	-0.20113	0.888296	0.190557	0.082047
128	27272401	2009	2010	1	1	1816941	-0.18761	0.813066	-0.58616	-0.25368	0.382245	-0.36435	0.52975
129	25612492	2011	2012	1		1880678	0.011929	0.352558	0.35099	0.011929	0.96026	-2.72222	7.402722
130	25649787	2011	2012	1	1	1942402	-0.22502	1.222146	-0.07653	-0.29873	0.613318	0.025332	0.685495