

JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH

EKONOMICKÁ FAKULTA

KATEDRA ÚČETNICTVÍ A FINANČÍ

DIPLOMOVÁ PRÁCE

TVORBA PREDIKČNÍCH MODELŮ

Vypracoval: Bc. Jakub Zabloudil

Vedoucí práce: Ing. Radek Zdeněk, Ph.D.

České Budějovice 2016

JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH

Fakulta ekonomická

Akademický rok: 2014/2015

ZADÁNÍ DIPLOMOVÉ PRÁCE

(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Bc. Jakub ZABLOUDIL**
Osobní číslo: **E14725**
Studijní program: **N6208 Ekonomika a management**
Studijní obor: **Účetnictví a finanční řízení podniku**
Název tématu: **Tvorba predikčních modelů**
Zadávající katedra: **Katedra účetnictví a financí**

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

Cíl práce:

Cílem práce je vytvořit vlastní modely pro předpověď úpadku podniku pomocí diskriminační analýzy a logistické regrese a vyhodnotit jejich vlastnosti. Práce bude zpracována v rámci projektu GAJU 149/2014/S.

Osnova:

1. Úpadek podniku a jeho predikce.
2. Predikční modely - historie, vlastnosti, spolehlivost, omezení.
3. Klasifikační metody - diskriminační analýza, logistická regrese.
4. Výběr a charakteristika vzorku podniků.
5. Výběr ukazatelů.
6. Tvorba vlastních predikčních modelů.
7. Vyhodnocení výsledků s důrazem na spolehlivost modelů.

Rozsah grafických prací:

Rozsah pracovní zprávy: 50 - 60 stran

Forma zpracování diplomové práce: tištěná

Seznam odborné literatury:

- Altman, E. I. (1968). *Financial ratios, discriminant analysis and the prediction of corporate bankruptcy*. *The Journal of Finance*, 23(4), pp. 589-609.
- Altman, E. I., & Hotchkiss, E. (2006). *Corporate financial distress and bankruptcy: Predict and avoid bankruptcy, analyze and invest in distressed debt* (3rd ed). Hoboken: Wiley.
- Beaver, W. H. (1966). *Financial Ratios As Predictors of Failure*. *Journal of Accounting Research*, 4(Empirical Research in Accounting: Selected Studies), pp. 71-111.
- Blaha, Z. S., & Jindřichovská, I. (2006). *Jak posoudit finanční zdraví firmy*. Praha: Management Press.
- Grünwald, R., & Holečková, J. (2009). *Finanční analýza a plánování podniku*. Praha: Ekopress.
- Havránek, T., & Vorlíček, J. (1980). *Lineární diskriminační funkce*. In: ROBUST '80. Praha: JČMF.
- Hebák, P. (2004). *Vícerozměrné statistické metody [1]*. Praha: Informatorium.
- Hebák, P. (2007). *Vícerozměrné statistické metody [3]*. Praha: Informatorium.
- Meloun, M., & Militký, J. (2006). *Kompendium statistického zpracování dat: metody a řešené úlohy* (2nd ed). Praha: Academia.
- Růčková, P. (2011). *Finanční analýza: Metody, ukazatele, využití v praxi*. Praha: GRADA Publishing.
- Řeháková, B. (2000). *Nebojte se logistické regrese*. *Sociologický časopis*, 36(4), pp. 475-492.
- Sedláček, J. (2011). *Finanční analýza podniku* (2nd ed). Brno: Computer Press.

Vedoucí diplomové práce:

Ing. Radek ZDENĚK, Ph.D.

Katedra účetnictví a financí

Datum zadání diplomové práce: 3. března 2015

Termín odevzdání diplomové práce: 15. dubna 2016

doc. Ing. Ladislav Rolínek, Ph.D.

děkan

JIHOČESKÁ UNIVERZITA
V ČESKÝCH BUDĚJOVICÍCH
EKONOMICKÁ FAKULTA
Studentská 13 (1)
370 05 České Budějovice

doc. Ing. Milan Jílek, Ph.D.

vedoucí katedry

V Českých Budějovicích dne 3. března 2015

Prohlášení

Prohlašuji, že svoji diplomovou práci jsem vypracoval samostatně pouze s použitím pramenů a literatury uvedených v seznamu citované literatury.

Prohlašuji, že v souladu s § 47 zákona č. 111/1998 Sb. v platném znění souhlasím se zveřejněním své diplomové práce, a to - v nezkrácené podobě elektronickou cestou ve veřejně přístupné části databáze STAG provozované Jihočeskou univerzitou v Českých Budějovicích na jejích internetových stránkách, a to se zachováním mého autorského práva k odevzdanému textu této kvalifikační práce. Souhlasím dále s tím, aby toutéž elektronickou cestou byly v souladu s uvedeným ustanovením zákona č. 111/1998 Sb. zveřejněny posudky školitele a oponentů práce i záznam o průběhu a výsledku obhajoby kvalifikační práce. Rovněž souhlasím s porovnáním textu mé kvalifikační práce s databází kvalifikačních prací Theses.cz provozovanou Národním registrem vysokoškolských kvalifikačních prací a systémem na odhalování plagiátů.

15. 4. 2016

Bc. Jakub Zabloudil

Poděkování

Tímto bych rád poděkoval panu Ing. Radku Zdeňkovi, Ph.D., za cenné odborné rady a připomínky, vstřícný přístup a trpělivost při zpracování této diplomové práce.

Obsah:

1	ÚVOD	3
2	ÚPADEK PODNIKU A JEHO PREDIKCE	4
2.1	ÚPADEK PODNIKU	4
2.2	FINANČNÍ TÍSEŇ PODNIKU	5
2.3	NÁKLADY FINANČNÍ TÍSNĚ	6
3	PREDIKČNÍ MODELÝ	8
3.1	HISTORIE PREDIKČNÍCH MODELŮ	8
3.2	PREDIKCE NA ZÁKLADĚ PENĚŽNÍCH TOKŮ	9
3.3	PREDIKCE NA ZÁKLADĚ POMĚROVÝCH UKAZATELŮ	10
3.4	BANKROTNÍ MODELÝ	11
3.5	OMEZENÍ A PROBLÉMY PREDIKČNÍCH MODELŮ	18
4	KLASIFIKAČNÍ METODY	19
4.1	CHARAKTERISTIKA KLASIFIKAČNÍCH METOD	19
4.2	TVORBA A DRUHY KLASIFIKAČNÍCH MODELŮ	19
4.3	DISKRIMINAČNÍ ANALÝZA	21
4.4	LOGISTICKÁ REGRESE	26
4.5	HODNOCENÍ KVALITY MODELU	29
4.6	VÝBĚR VZORKU V KVANTITATIVNÍM VÝZKUMU	32
5	METODIKA	34
5.1	CÍLE PRÁCE	34
5.2	VYUŽÍVANÝ SOFTWARE	34
5.3	VYMEZENÍ ÚPADKOVÝCH PODNIKŮ A VOLBA VSTUPNÍCH DAT	34
5.4	VÝBĚR POMĚROVÝCH UKAZATELŮ	35
5.5	POPIS DÍLČÍCH POSTUPŮ	37
6	OVĚŘENÍ STÁVAJÍCÍCH KLASIFIKAČNÍCH MODELŮ	41
6.1	ALTMANOVO Z'	41
6.2	ALTMANOVO Z''	45
6.3	INDEX IN95	47
6.4	INDEX IN99	50
6.5	INDEX IN01	53
6.6	INDEX IN05	56
6.7	TAFFLERŮV ZÁKLADNÍ MODEL	58
6.8	TAFFLERŮV MODIFIKOVANÝ MODEL	61
6.9	GURČÍKŮV INDEX	63
6.10	SHRNUTÍ VÝSLEDKŮ OVĚŘENÍ MODELŮ A OPTIMALIZACE	66

7	PROFILOVÁ ANALÝZA	69
7.1	GRAFICKÁ PROFILOVÁ ANALÝZA	69
7.2	TESTOVÁNÍ SHODY STŘEDNÍCH HODNOT UKAZATELŮ	74
7.3	VYHODNOCENÍ VÝSLEDKŮ PROFILOVÉ ANALÝZY	76
8	TVORBA VÍCEROZMĚRNÉHO MODELU DISKRIMINAČNÍ ANALÝZOU	77
8.1	TESTY NORMALITY	77
8.2	TVORBA MODELU	78
8.3	OVĚŘENÍ SPOLEHLIVOSTI VYTVOŘENÝCH MODELŮ	82
8.4	OPTIMALIZACE DĚLÍČÍHO BODU VYTVOŘENÝCH MODELŮ	83
8.5	VÝBĚR FINÁLNÍHO MODELU	84
9	TVORBA VÍCEROZMĚRNÉHO MODELU LOGISTICKOU REGRESÍ	86
9.1	TVORBA MODELU	86
9.2	OVĚŘENÍ SPOLEHLIVOSTI A OPTIMALIZACE DĚLÍČÍHO BODU	87
10	SROVNÁNÍ SPOLEHLIVOSTI VYTVOŘENÝCH A STÁVAJÍCÍCH MODELŮ	90
11	ZÁVĚR	91
12	SUMMARY AND KEYWORDS	93
13	SEZNAM LITERATURY	94
14	SEZNAM TABULEK, GRAFŮ A OBRÁZKŮ	97
15	SEZNAM ZKRATEK A SYMBOLŮ	100
16	SEZNAM PŘÍLOH	101

1. ÚVOD

V současné turbulentní době dochází k neustálým změnám tržního prostředí. Konkurence se stále zvětšuje, požadavky ze strany legislativy zpřísnují a stávající podniky tak čelí větším výzvám ve snaze dosáhnout úspěchu či pouze obstát. Přesto každým rokem vznikají desítky tisíc nových subjektů. Stačí však relativně málo a podnik se může ocitnout ve vážných problémech, mnohdy končících jeho úpadkem. Kromě existenčních dopadů na daný podnik však lze pozorovat nebezpečí v negativním vlivu na ostatní subjekty, například finanční instituce, domácnosti nebo na obchodní partnery, kteří se tak mohou ocitnout v druhotné platební neschopnosti. Dle údajů společnosti CRIF – Czech Credit Bureau během roku 2015 zbankrotovalo přes tisíc obchodních společností. Tato skutečnost podtrhuje potřebu existence modelů včasného varování, resp. bankrotních modelů, jejichž účelem je s určitým předstihem odhalit finanční tíseň a umožnit tak odvrátit potenciální úpadek.

Cílem této práce je vytvořit vlastní modely pro předpověď úpadku podniku pomocí diskriminační analýzy a logistické regrese a vyhodnotit jejich vlastnosti. Nejdříve dojde k vymezení problematiky z pohledu odborné literatury. V druhé kapitole lze najít definici úpadku a shrnutí legislativní úpravy. Dále následuje popis finanční tísně a nákladů, které se k nim vztahují. Třetí kapitola se věnuje predikčním modelům. Po shrnutí jejich historického vývoje budou vymezeny přístupy k predikci, stejně jako možná omezení a problémy. Velká pozornost je věnována již existujícím bankrotním modelům. Čtvrtá kapitola se zabývá klasifikačními metodami. Po stručné charakteristice dojde k naznačení procesu jejich tvorby. Obsahem následující části práce je popis diskriminační analýzy a logistické regrese, včetně způsobů hodnocení kvality vytvořeného modelu.

Praktická část začíná pátou kapitolou a metodickým vymezením postupů, včetně definice dílčích cílů, výběru vzorku podniků a volbou poměrových ukazatelů. V šesté kapitole bude ověřena klasifikační spolehlivost vybraných stávajících modelů. Následně dojde k pokusu o zvýšení této spolehlivosti aplikací vhodnějšího dělicího bodu pro klasifikaci. Předmětem sedmé kapitoly je provedení profilové analýzy, a to jak graficky, tak i prostřednictvím statistických testů shody středních hodnot. Osmá kapitola je zaměřena na tvorbu modelu diskriminační analýzou, ověření klasifikační spolehlivosti. Rovněž dojde k pokusu o zvýšení počtu správně zařazených subjektů optimalizací prahové hodnoty. Vytvoření modelu prostřednictvím logistické regrese je potom obsahem deváté kapitoly.

2. Úpadek podniku a jeho predikce

První kapitola se zabývá několika důležitými pojmy, které se neoddělitelně váží k tématu práce. Nejdříve bude definován úpadek podniku a jeho legislativní úprava. Poté následuje popis finanční tísně podniku z pohledu různých autorů. S finanční tísní jsou rovněž spojeny nezanedbatelné náklady, jejichž popisuje věnována poslední část této kapitoly.

2. 1. Úpadek podniku

Literatura rozlišuje několik pojmů spojených s úpadkem podniku. Tzv. technická insolvence nastane v případě, že podnik neplní své současné závazky a značí nedostatek likvidity. Takový případ může být pouze přechodnou záležitostí, avšak často je označován jako okamžitá příčina formálního vyhlášení úpadku. Insolvence ve smyslu úpadku je více kritická a představuje spíše chronickou nežli dočasnou situaci. Celkové závazky takového podniku převyšují celkovou hodnotu jeho aktiv v tržním ocenění a výše vlastního kapitálu se stává zápornou. Vlastníci (kmenoví akcionáři) tak ztratí své investice, které vložili do akcií. Technickou insolvenční lze snadno odhalit, kdežto vážnější insolvence v úpadkovém smyslu vyžaduje komplexní oceňovací analýzu. Jako finanční selhání je pak uvažována široká škála situací, které mohou nastat mezi těmito dvěma mezními situacemi. Samotný pojem úpadek lze tedy vztáhnout buď k negativnímu rozdílu mezi sumou aktiv a závazků, nebo k formálnímu vyhlášení úpadku u soudu. Následně může dojít k likvidaci či pokusu o uzdravení (Altman & Hotchkiss, 2006; Blaha & Jindřichovská, 2006).

Nezbytnou součástí řešení problematiky úpadku je vytvoření kvalitního úpadkového práva, které umožní rychlý odchod z hospodářského systému těch subjektů, působících negativně na ostatní z důvodu svého úpadku. Výsledkem tak bude omezení ztrát a ostatních nežádoucích dopadů na další podnikatele, finanční instituce a domácnosti (Rýdl, 2005).

Současně platným právním předpisem, upravujícím úpadek podniku, je zákon č. 182/2006 Sb., o úpadku a způsobech jeho řešení (insolvenční zákon). Tento zákon je účinný od 1. ledna roku 2008. Podmínky, určující úpadek dlužníka, jsou řešeny v §3 následovně:

„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“ (Zákon č. 182/2006 Sb., o úpadku a způsobech jeho řešení, §3, odstavec 1)

Neschopnost plnění peněžitých závazků je blíže upřesněna v odstavci 2. Takový stav nastane, pokud:

„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“ (Zákon č. 182/2006 Sb., o úpadku a způsobech jeho řešení, §3, odstavec 2)

Definici úpadku rozšiřuje odstavec 3o předlužení. Na základě zmíněného odstavce se o předlužení jedná v případě, že daný dlužník má více věřitelů a jeho závazky v souhrnu převyšují hodnotu majetku tohoto dlužníka (Zákon č. 182/2006 Sb., o úpadku a způsobech jeho řešení, §3, odstavec 3).

Základem úpadku je tedy mnohost věřitelů, tzn., že dlužník má alespoň dva věřitele. Současné není rozhodující, v jaké výši tyto závazky dlužníka vůči věřiteli jsou. Úpadek může obecně nastat následkem platební neschopnosti nebo v důsledku předlužení. Samotné zjištění obou jeho forem současně není nutné (Maršíková, 2011).

2.2. Finanční tíseň podniku

Finanční tíseň lze označit za jev, který provází fungování tržní ekonomiky a projevuje se obzvláště při hlubších depresích ekonomiky nebo v obdobích transformačních změn. Za neobvyklé však není možné považovat, pokud se takový stav naskytne i za běžných podmínek fungování ekonomiky. Mnoho analýz označuje za hlavní příčinu vzniku finančních tísní kvalitu managementu a jejich rozhodování. Její podobu lze rozlišit na relativní (podnik není schopen uhradit své současné závazky, přestože souhrnná výše aktiv převyšuje celkové závazky) a absolutní, kdy úhrn aktiv podniku nabývá nižší hodnoty než závazky (Valach, 2010).

Definice finanční tísně je problematickou záležitostí. Často bývá charakterizována jako přímý opak naprostého finančního zdraví, přičemž mezi nimi může vyskytnout množství přechodových fází a různých stavů. U českých podniků je např. častým jevem ziskovost podniku, avšak provází ji problémy s likviditou (podniky ve fázi růstu). Nelze tedy jednoznačně kvantitativně určit moment přechodu z menších finančních problémů do situace závažné finanční tísně. Obecně jde však charakterizovat finanční tíseň podniku jako stav, kdy vykazuje tak závažné potíže s likviditou, že je není možné vyřešit jinak než podstatnou změnou v provozní činnosti nebo ve způsobu financování. Provozní, resp. finanční restrukturalizace či reorganizace pak představují změny k zastavení či odvrácení cesty k úpadku (Grünwald & Holečková, 2009; Holečková, 2008; Mrkvička&Kolář, 2006).

Gurčík (2002) považoval za prosperující podnik takový, který ve sledovaném období tří let (1998-2000) generoval zisk a v posledním roce vykazoval rentabilitu vlastního kapitálu nad osm procent. Pokud subjekt v daných třech letech vykazoval ztrátu, spadal do skupiny neúspěšných.

Podle Synka (2007) lze u podniků, procházejících krizí, spatřovat tři klíčové situace směřování k úpadku:

- Podnik se vyznačuje dlouhodobou ztrátovostí a platební neschopností
- V podniku se nacházejí tyto dílčí, avšak závažné potíže: dochází k poklesu objemu výkonů, existuje nepříznivé sociální klima uvnitř společnosti a problematika trvalé platební neschopnosti.
- Finanční tíseň se dá rovněž členit do dvou forem:
 - Relativní neschopnost, když podnik není schopen dostát všem splatným závazkům ke stanovenému termínu, na daném místě a v určené podobě.
 - Absolutní neschopnost, při které hodnota závazků podniku převyšuje hodnotu aktiv (Marek, 2006).

2.3. Náklady finanční tísně

Pokud se podnik ocitne ve finanční tísně, vznikají mu jisté dodatečné náklady – náklady finanční tísně. Tyto náklady a právní úprava mají důležitou roli. Zejména to platí u malých podniků, u kterých mohou náklady vynaložené na případnou reorganizaci snadno převýšit zbývající hodnotu podniku. Význam nákladů finanční tísně u velkých podniků spočívá především v obrovských poplatcích. Například

poplatky poradcům při známém úpadku společnosti Enron údajně převýšily 1 miliardu amerických dolarů. Vznik těchto nákladů je spojený s určitou pravděpodobností a samotné náklady mají různý charakter a velikost. Do nákladů finanční tísně lze zahrnout náklady úpadku nebo náklady konfliktu zájmů vlastníků a manažerů, popř. věřitelů. Obecně se dělí na náklady přímé a nepřímé (Altman, 2006; Valach, 2010).

Příkladem přímých nákladů úpadku mohou být poplatky právníkům, různým poradcům či expertním svědkům. Nepřímé náklady zahrnují široké spektrum nákladů příležitosti. Věřitelé, např. banky, si kompenzují vyšší riziko zvýšením požadovaných úroků. Také obchodní partneři prokazují nižší nájem o dodávky podniku, který se nachází v úpadku. Často dochází ke vzniku nezanedbatelných nákladů, spojených s odchodem vysoce kvalifikovaných zaměstnanců (Altman, 2006).

3.Predikční modely

Široké spektrum zájmových skupin, zejména investoři a věřitelé, velmi ocení včasné varování před nastávající finanční tísňí. Ideálně dříve, než ji vytyší širší veřejnost. Po propuknutí finanční tísně totiž dochází ke značnému poklesu kurzu cenných papírů a ke zhoršení bonity. Investoři tak prodají své akcie a věřitelé dluhopisy. Predikce je založena na poznatku, že s pokračujícím zhoršováním finanční situace dospěje podnik v určité fázi do situace, ze které již nebude cesty ven. Aplikace predikčních modelů by měla identifikovat hrozící úpadek rok, nebo i více let předem (Grünwald & Holečková, 2009).

Predikční modely lze členit na bankrotní a bonitní. Bankrotní modely jsou založeny na využití skutečných údajů, přičemž se snaží určit, zda daný podnik do určité doby zbankrotuje a poskytnout tak jakési včasné varování. Naproti tomu bonitní modely vycházejí spíše z teoretických poznatků, avšak pracují i s empirickými poznatky analytiků. Jejich úkolem je posouzení, zda je či není analyzovaný podnik zdravý (Holečková, 2008).

3.1. Historie predikčních modelů

Původní studie, zaměřené na užití poměrových ukazatelů pro predikci úpadku, se zabývaly individuálními ukazateli a porovnáním jejich hodnot u neúspěšných a úspěšných podniků. Roku 1932 FitzPatrick aplikoval třináct poměrových ukazatelů na 38 podniků (19 úspěšných a 19 neúspěšných) a porovnal je. Ve srovnání se „standardními“ hodnotami poměrových ukazatelů a jejich trendy vykazovaly úspěšné firmy v převládající většině případů příznivé hodnoty poměrových ukazatelů a naopak. V následujících letech vzniklo několik dalších studií, zaměřených na nalezení nejvhodnějších ukazatelů pro predikci úpadku. Oblastí soustředění byly různé druhy podniků (odvětví, velikost) nebo vzory finanční struktury. Práce dále zkoumaly signály, značící potíže, a počet let před úpadkem, ve kterých se tyto signály začaly projevovat (Belloc & Giacomino & Akers, 2007).

Významnou práci v roce 1966 publikoval a roku 1968 dále rozpracoval William Beaver. Soustředil se na predikci úpadku za použití jednorozměrné diskriminační analýzy. Model vytvořil na základě určitého počtu finančních ukazatelů, které vybral pomocí dichotomních klasifikačních testů. Sám Beaver ale připustil, že použití více ukazatelů současně může mít vyšší předpovídající schopnost než zvážení pouze jednoho poměrového ukazatele. To odstartovalo evoluci predikčních modelů. První studií,

zaměřující se na využití vícerozměrných metod predikce, publikoval v roce 1968 Edward Altman. Altman prostřednictvím vícerozměrné diskriminační analýzy vyvinul model, obsahující pět ukazatelů zároveň, tzv. Z-skóre. Ten byl poté několikrát upraven a modifikován. Mnohonásobná diskriminační analýza byla až do počátku osmdesátých let minulého století stěžejní metodou předpovědi úpadku podniku (Bellovary & Giacomino & Akers, 2007; Balcaen & Ooghe, 2006).

Pro další etapu jsou charakteristické méně „náročné“ statistické techniky, jako logistická regrese, probitová regrese či modely lineární pravděpodobnosti. Tyto metody vyústily v modely podmíněné pravděpodobnosti. Využití logistické regrese pro předpověď úpadku rozpracoval James Ohlson v roce 1980¹. Průkopníkem v oblasti použití probitové regrese, proti jejímuž častějšímu použití však svědčí vyšší výpočetní náročnost, byl svou prací z roku 1984 Mark Zmijewski² (Balcaen & Ooghe, 2006).

Technologický rozvoj spolu se zvýšením dostupnosti a síly počítačového zpracování dat umožnily vznik širšího spektra metod pro předpověď úpadku. Pozornost je věnována různým statistickým technikám a uměle inteligentním systémům, jako jsou fuzzy množiny, neuronové sítě, rough množiny, případové usuzování, metoda „support vector machines“, metody analýzy obalu dat (DEA), metoda „soft computing“, rozhodovací stromy, genetické algoritmy, rekurzivní dělení a další (Jackson & Wood, 2013; Kumar & Ravi, 2007).

3.2. Predikce na základě peněžních toků

William Beaver ve své práci z roku 1966 vysvětloval teorii analýzy poměrových ukazatelů a jejich testování v rámci modelu cash flow. Na podnik je zde nahlíženo jako na určitý rezervoár likvidních aktiv. Ten je doplňován jejich přítoky a vyprazdňován odtoky a slouží jako určitý polštář či nárazník pro případné výkyvy toků. Platební schopnost podniku zde Beaver definuje v podmínkách pravděpodobnosti vyčerpání tohoto rezervoáru, kdy již podnik nebude schopen hradit své splatné závazky. Vztah mezi tokem likvidního majetku a poměrovými ukazateli je dán čtyřmi pojetími. Prvním je samotná velikost rezervoáru. Čím je větší, tím nižší je pravděpodobnost úpadku.

¹ Viz kapitola 3.4.5. Ohlsonův model

² Zmijewski rovněž zkoumal dva potenciálně negativní vlivy, nacházející se ve většině předcházejících studií. První odchýlení může nastat při výběru vzorku podniků v případě, pokud analytik nejdříve sleduje závisle proměnnou a teprve na tomto základě vybírá vzorek. Jako druhé nežádoucí odchýlení, spojené s výběrem vzorků podniků, označuje odhad modelu pouze na základě pozorování s kompletní datovou základnou (výkazy daného období), přičemž pozorování s neúplnými údaji se objevují nenáhodně (Zmijewski, 1984).

Druhý vliv je vztažen k cash flow z provozní činnosti. Zde rovněž platí, že čím je tento peněžní tok větší, tím je úpadek méně pravděpodobný. Jako třetí je výše dluhu drženého daným podnikem. Zde platí, že čím vyšší je dluhová zátěž podniku, tím pravděpodobněji nastane úpadek. Čtvrtým je fond pro výdaje z provozní činnosti, kde opět funguje vztah přímé úměry mezi jejich velikostí a náchylností k úpadku (Beaver, 1966).

Než se podnik dostane do úpadku, prochází těmito etapami:

1. Úbytek Cash Flow Netto
2. Snížení čistého cash flow z provozní činnosti
3. Potíže s cash flow z finanční činnosti
4. Potíže v investiční činnosti
5. Finanční tíseň z důvodu platebních potíží
6. Předlužení
7. Tlak ze strany věřitelů
8. Vyhlášení úpadku

Identifikace příslušné etapy se provede dle signálů, které poskytnou peněžní toky a poměrové ukazatele. Od páté fáze již nastává finanční tíseň, proto je pro včasnou předpověď nutné rozpoznání nepříznivého vývoje již v některé z prvních čtyř etap (Grünwald & Holečková, 2009).

3.3. Predikce na základě poměrových ukazatelů

Podstatou této metody předpovědi úpadku je statistické sledování chování předem stanovených poměrových ukazatelů v různých úpadkových podnicích. Výsledek, tedy zjištěné charakteristické indikátory finanční tísně, je následně použit pro nalezení případných kandidátů na úpadek (Grünwald & Holečková, 2009).

V roce 1966 vytvořil William Beaver tzv. profilovou analýzu, patřící do kategorie jednorozměrných analýz. Nejprve porovnal 79 úspěšných podniků se stejně početnou skupinou podniků neúspěšných (v daném období ohlášený úpadek, nedodržení závazků z emitovaných dluhopisů, překročení úvěrového rámce či nevyplacení dividendy z prioritních akcií). Neúspěšné podniky byly klasifikovány dle odvětví (38 odlišných odvětví) a velikosti aktiv. Výběr podniků vycházel z párování vzorků, resp. ke každému neúspěšnému podniku byl vybrán úspěšný ze stejného odvětví a stejnou velikostí aktiv.

Proběhl výpočet průměrných hodnot pro třicet poměrových ukazatelů. Po provedení dichotomního klasifikačního testu se statisticky nejvíce spolehlivými ukázalo těchto šest ukazatelů:

- Peněžní tok / Cizí kapitál
- Zisk po zdanění / Aktiva
- Cizí kapitál / Aktiva
- Pracovní kapitál / Aktiva
- Oběžná aktiva / Krátkodobá pasiva
- No Credit Interval

Pět let před nastáním krizového stavu byly zjištěny značně odlišné průměrné hodnoty úspěšných a neúspěšných podniků. Zároveň čím více se blížil rok selhání, tím větší rozdíl byl pozorován. Pokles těchto ukazatelů po dobu tří let je indikací, že do dvou let nastane finanční tíseň (Beaver, 1966; Grünwald & Holečková, 2009; Marek, 2009).

3.4. Bankrotní modely

Bankrotní modely jsou nástrojem, jehož pomocí lze analyzovat finanční situaci podniku a posoudit jeho finanční zdraví. Podkapitola je věnována popisu známých predikčních modelů, využívajících diskriminační analýzu nebo logistickou regresi. Výsledkem diskriminační analýzy jsou vícerozměrné modely, složené z více poměrových ukazatelů, kterým jsou přiřazeny váhy. Na základě výsledného váženého součtu je možné posoudit, zda se jedná o podnik směřující k úpadku či nikoliv. Logistická regrese naopak pracuje s pravděpodobností úpadku podniku.

3.4.1. Modely E. Altmana

První vícerozměrný model, vytvořený profesorem Altmanem, bylo tzv. Z-skóre. Data z finančních výkazů jsou kombinována s měřítky tržní hodnoty. Výsledné skóre bylo následně užito k rozlišení sledované firmy, zda nabývala či nenabývala charakteru finanční tísně. Jako statistická klasifikační metoda byla použita diskriminační analýza, umožňující rozlišit nebo předpovědět zdraví podniků. Obecný tvar lineární funkce, ze které Z-skóre vychází, má tvar $Z = a_1 \cdot x_1 + a_2 \cdot x_2 + a_3 \cdot x_3 + \dots + a_n \cdot x_n$. Koeficienty a představují konstantní hodnoty vah. Jako x jsou označeny diskriminační proměnné, resp. jednotlivé poměrové ukazatele (Altman & Hotchkiss, 2006).

Z původních dvaadvaceti ukazatelů bylo nakonec vybráno (např. podle popularity v literatuře nebo účelové vhodnosti) pět nejvhodnějších. Výsledný Z'-skóre model měl následující podobu:

$$Z = 1,2 \cdot X_1 + 1,4 \cdot X_2 + 3,3 \cdot X_3 + 0,6 \cdot X_4 + 1,0 \cdot X_5$$

Kde: X_1 =Pracovní kapitál/Celková aktiva, X_2 =Zadržený zisk/Celková aktiva, X_3 =Provozní zisk před úroky a zdaněním/Celková aktiva, X_4 =Tržní kapitalizace/Cizí kapitál, X_5 =Tržby/Celková aktiva

Jako ukazatel, který nejvíce relativně přispívá k diskriminační síle této funkce, se projevil ukazatel ziskovosti X_3 , což není vzhledem k účelu modelu překvapivé. Hodnoty vah (konstantních koeficientů) rovnice takto vyšly výpočtem počítačového algoritmu. Všechny diskriminační koeficienty (váhy) jsou pozitivního charakteru. Z toho by se dal vyvodit závěr, že čím vyšší je výsledné skóre, tím je potenciál podniku k úpadku vyšší. Avšak aplikacemi modelu a sledováním chybně klasifikovaných podniků byly vyvozeny určité hranice. Pokud Z-skóre nabývá hodnoty větší než 2,99, podnik je neúpadkový. Na druhou stranu skóre pod 1,81 značí úpadkový podnik. Oblast mezi 1,81 a 2,99 je definována jako tzv. šedá zóna a nelze s přesností určit, do které skupiny podnik spadá (Altman, 1968; Marek, 2009).

Úvěroví analytici, auditoři a další subjekty však v tomto modelu spatřovali jeden podstatný problém, a sice neaplikovatelnost na neveřejně obchodovatelné podniky. Ukazatel X_4 totiž vyžaduje údaje o tržní ceně akcií. Z tohoto důvodu zde byla tržní kapitalizace zaměněna s hodnotou vlastního kapitálu a výsledná modifikace pro neveřejně obchodované podniky má tuto podobu:

$$Z' = 0,717 \cdot X_1 + 0,847 \cdot X_2 + 3,107 \cdot X_3 + 0,420 \cdot X_4 + 0,998 \cdot X_5$$

Kde: X_1, X_2, X_3 a X_5 jsou stejné jako v modelu Z-skóre

X_4 =Vlastní kapitál/Cizí kapitál

Klasifikace dle nového Z'skóre se rovněž odvíjí od vymezených hranic. Neúpadkový podnik nabývá skóre vyššího než 2,90. Hodnota 1,23 a nižší naopak poukazuje na úpadkový podnik. Mezi těmito hodnotami se opět nachází tzv. šedá zóna (Altman, 2000; Altman & Hotchkiss, 2006).

Poslední varianta vznikla po posouzení charakteru a přesnosti modelu bez proměnné X_5 (Tržby /Celková aktiva). Nový Z'' -skóre model, vhodný pro nevýrobní a začínající podniky, vypadá následovně:

$$Z'' = 6,56 \cdot X_1 + 3,26 \cdot X_2 + 6,72 \cdot X_3 + 1,05 \cdot X_4$$

Kde: X_1, X_2, X_3 a X_4 jsou stejné jako v předchozím modelu Z'

Pro minimalizaci případného efektu odvětví byl ukazatel X_5 odstraněn. Tento model může být rovněž užitečný např. v případě aplikace na podniky z odvětví, ve kterém se liší způsoby financování aktiv (Altman, 2000; Altman & Hotchkiss, 2006).

3.4.2. Modely IN

Pro posouzení finanční výkonnosti a důvěryhodnosti podniků v České republice vytvořili manželé Inka a Ivan Neumaierovi čtyři indexy. Jejich označení vyplývá ze jmen autorů (první dvě písmena) následovaných dvojčíslic, které vyjadřuje rok vzniku. Prvním z nich byl bankrotní index IN95. Po čtyřech letech Neumaierovi vytvořili index IN99, sloužící k posouzení bonity zkoumaného podniku. Spojením těchto dvou potom vznikl o dva roky později index IN01, aktualizovaný v roce 2005 na index IN05 (Sedláček, 2011).

Index IN95

Tento model byl vytvořen v roce 1995 na základě analýzy některých významných bankrotních indikátorů (zkoumáno bylo dvacet čtyři empiricko-induktivních systémů ukazatelů, vzniklých na základě ratingových modelů a praktických zkušeností) a ukazatelů, které tyto indikátory považují za nejvýznamnější či jsou nejvíce používané. Důraz klade na hledisko věřitele, proto je často označován jako index důvěryhodnosti. Při předpovědi finanční tísně nabývá tento model více než sedmdesátí procentní úspěšnosti. Pro ekonomiku České republiky mají váhy, a tedy i index následující podobu:

$$IN95 = 0,22 \cdot X_1 + 0,11 \cdot X_2 + 8,33 \cdot X_3 + 0,52 \cdot X_4 + 0,1 \cdot X_5 - 16,8 \cdot X_6$$

Kde: X_1 =Celková aktiva/Cizí kapitál, X_2 =Provozní zisk před úroky a zdaněním/Nákladové úroky, X_3 =Provozní zisk před úroky a zdaněním/Celková aktiva, X_4 =Celkové výnosy/Celková aktiva, X_5 =Oběžná aktiva/Krátkodobé závazky a

krátkodobé bankovní úvěry a výpomoci, X_6 =Závazky po lhůtě splatnosti/ Celkové výnosy

Váhy jednotlivých ukazatelů stanovili manželé Neumaierovi na základě podílu významnosti ukazatele podle četnosti jeho výskytu a odvětvové hodnoty, které nabýval v roce 1994. Pro jednotlivá odvětví se váhy liší, což umožňuje zohlednit případná odvětvová specifika. Pokud index nabývá hodnoty 2 a vyšší, podnik bezproblémově hradí své závazky. Rozmezí tzv. šedé zóny se pohybuje od 1 do 2 a představuje rizikové podniky, které mohou mít problémy se splácením závazků. V případě výsledku nižšího než 1, je již analyzovaný podnik problémový a má nedostatečnou schopnost hrazení svých závazků (Neumaierová, Neumaier, 2002; Sedláček, 2011).

Index IN99

Model se soustředí na pohled samotného vlastníka. Důležitost ukazatelů z pohledu tvorby hodnoty určili autoři pomocí diskriminační analýzy. Váhy z modelu IN95, platné pro ekonomiku ČR, byly revidovány s ohledem na dosažení kladného ekonomického zisku (EVA). Vznikl tento bonitní index:

$$IN99 = -0,017 \cdot X_1 + 4,573 \cdot X_2 + 0,481 \cdot X_3 + 0,015 \cdot X_4$$

Kde: X_1 =Celková aktiva/Cizí kapitál, X_2 =Provozní zisk před úroky a zdaněním/Celková aktiva, X_3 =Celkové výnosy/Celková aktiva, X_4 = Oběžná aktiva/Krátkodobé závazky a krátkodobé bankovní úvěry a výpomoci

Hodnota IN99 větší než 2,07 představuje kladný ekonomický zisk. Podnik naopak dosahuje záporného ekonomického zisku, pokud je hodnota menší než 0,684. Interval tzv. šedé zóny je zde poměrně široký a dá se rozdělit na tři pásma. IN99 mezi 1,420 a 2,07 značí podnik, který na tom není špatně. V mezích 1,089 až 1,420 se jedná o nerozhodnou situaci s jistými přednostmi, ale i problémy daného podniku. Pásmo 0,684 až 1,089 již poukazuje na problémový podnik (Neumaierová, Neumaier, 2002).

Model je schopen posoudit situaci podniku s úspěšností větší než osmdesát pět procent. Jelikož naplnění věřitelského kritéria není pro vlastníka postačující podmínkou, doplňuje se s indexem IN95. Schopnost plnění svých závazků totiž ještě neznamená tvorbu hodnoty pro vlastníky (Sedláček, 2011).

Index IN01

Snaha o konstrukci modelu, spojujícího předchozí dva indexy, vyústila v roce 2002 ve vytvoření indexu IN01. Zkoumaných 1915 průmyslových podniků autoři rozdělili na tři skupiny. První čítala 583 podniků, které tvořily hodnotu. Dalších 503 podniků se nacházelo v úpadku, resp. těsně před úpadkem. Zbývajících 829 „ostatních“ podniků tvoří poslední skupinu. Za využití diskriminační analýzy byl zkonstruován následující model:

$$IN01 = 0,13 \cdot X_1 + 0,04 \cdot X_2 + 3,92 \cdot X_3 + 0,21 \cdot X_4 + 0,09 \cdot X_5$$

Kde: X_1 až X_5 jsou shodné s ukazatelem IN95

Pro podnik, tvořící kladný ekonomický zisk (s pravděpodobností 67%), nabývá funkce hodnotu větší než 1,77. V situaci výsledku menšího než 0,75 směřuje podnik s 86% pravděpodobností k úpadku. Tzv. šedá zóna se nachází mezi těmito hodnotami (Neumaierová, Neumaier, 2002).

Index IN05

Manželé Neumaierovi se rozhodli testovat vypovídací schopnost předchozích třech indexů. Za základnu použili data 1526 průmyslových podniků za rok 2004 rozdělených dle hrozby úpadku a dle tvorby hodnoty (pomocí metodiky INFA³). Úspěšnost klasifikace podniků prostřednictvím modelu IN95 se na těchto datech zlepšila na 80 %. Index IN99 šel však s úspěšností predikce pod 50 %. Model IN01 si svoji úspěšnost víceméně udržel, neboť nepatrně klesla na 74 %. Na základě aktualizace předchozího modelu vznikl, rovněž pomocí diskriminační analýzy, poslední ze čtyř indexů manželů Neumaierových:

$$IN05 = 0,13 \cdot X_1 + 0,04 \cdot X_2 + 3,97 \cdot X_3 + 0,21 \cdot X_4 + 0,09 \cdot X_5$$

Kde: X_1 až X_5 jsou shodné s ukazatelem IN95

Jednotlivé hodnoty vah oproti indexu IN01 se příliš nezměnily. Ke změně však došlo u hranic zařazení podniků. Výsledek indexu u úspěšných podniků je vyšší než 1,60. Pro

³ INFA představuje pyramidový ukazatelový systém, umožňující vysvětlit vývoj a výši krátkodobé i dlouhodobé výkonnosti podniku. Komplexně hodnotí finanční situaci. Rovněž dokáže jasně oddělit tvorbu provozního zisku před úroky a zdaněním (EBIT), jeho členění a vazby mezi životností aktiv a závazků (Neumaierová, Neumaier, 2014)

úpadkové podniky nabývá funkce hodnoty nižší než 0,90. Mezi těmito hodnotami se opět nachází tzv. šedá zóna (Neumaierová, Neumaier, 2005).

Předností modelu je možnost využití pro podniky na kapitálovém trhu obchodované i neobchodované. Nejvyšší vypovídací schopnost index poskytne u středně velkých a velkých průmyslových podniků. Přestože jeho pomocí lze odhadnout výkonnost daného podniku, neřeší tento index způsob jejího dosažení (Neumaierová, Neumaier, 2008).

3.4.3. Tafflerův model

Tafflerův model byl vytvořen za účelem analýzy britských podniků. Výchozí soubor obsahoval přes osmdesát poměrových ukazatelů. Nakonec došlo k výběru čtyř ukazatelů, které dokázaly nejlépe rozlišit úpadkové a neúpadkové podniky. Samotný Taffler však naznačil, že model dokáže pouze určit, zda se finanční profil analyzovaného podniku podobá úspěšným nebo neúspěšným podnikům. Základní podoba Tafflerova modelu vypadá následovně:

$$T(z) = 0,53 \cdot X_1 + 0,13 \cdot X_2 + 0,18 \cdot X_3 + 0,16 \cdot X_4$$

Kde: X_1 =Zisk před zdaněním/Krátkodobé závazky a krátkodobé bankovní úvěry, X_2 =Oběžná aktiva/Cizí kapitál, X_3 =Krátkodobé závazky a krátkodobé bankovní úvěry/Celková aktiva, X_4 =(Finanční majetek minus krátkodobé závazky a krátkodobé bankovní úvěry)/Provozní náklady

Velká pravděpodobnost úpadku je spjata s hodnotou menší než nula. Pokud funkce naopak vyjde vyšší než nula, pravděpodobnost úpadku je malá. Modifikovaný Tafflerův model vypadá takto:

$$T(m) = 0,53 \cdot X_1 + 0,13 \cdot X_2 + 0,18 \cdot X_3 + 0,16 \cdot X_4$$

Kde: X_1 až X_3 jsou shodné se základním modelem, X_4 =Celkové tržby/Celková aktiva

Od základního modelu se modifikovaný liší pouze odlišným posledním ukazatelem X_4 . Váhy, jejichž součet je roven jedné, zůstaly nezměněné. Velkou pravděpodobnost úpadku značí hodnota pod 0,2. Výsledek vyšší než 0,3 představuje malou pravděpodobnost úpadku analyzovaného podniku (Holečková, 2008; Sedláček, 2011).

3.4.4. Gurčíkův index

Gurčík (2002) vycházel z 60 náhodně vybraných zemědělských podniků. Klíčovým faktorem kvality modelu bylo jejich rozdělení na prosperující a neprospírající, kdy toto kritérium bylo popsáno v kapitole 2.2. Z původních 35 finančních ukazatelů bylo pomocí dvoustranného t-testu shody středních hodnot a dle subjektivního zhodnocení vybráno těchto pět proměnných:

X_1 = Nerozdělený výsledek hospodaření/Celková pasiva

X_2 = Výsledek hospodaření před zdaněním/Celková pasiva

X_3 = Výsledek hospodaření před zdaněním/Výnosy celkem

X_4 = Cash Flow/Pasiva celkem

X_5 = Zásoby/Výnosy celkem

Aplikací diskriminační analýzy na těchto pět ukazatelů vznikla následující rovnice, na základě které lze vypočítat hodnotu G-indexu:

$$G = 3,412 \cdot X_1 + 2,226 \cdot X_2 + 3,277 \cdot X_3 + 3,149 \cdot X_4 - 2,063 \cdot X_5$$

U prosperujících podniků nabývá G-index hodnoty větší nebo rovno 1,8. V případě průměrných podniků se výsledná hodnota nachází mezi -0,6 a 1,8. Podniky, klasifikované jako neprospírající, mají G-index nižší nebo roven -0,6 (Gurčík, 2002).

3.4.5. Ohlsonův model

Americký ekonom James A. Ohlson se zabýval využitím logistické regrese pro předpověď úpadku podniku. Logistickou regresi upřednostňoval proto, aby se vyhnul známým problémům spojeným s mnohonásobnou diskriminační analýzou. Základní otázku ve vztahu k odhadu lze formulovat takto: jaká je pravděpodobnost úpadku během určitého časového úseku za předpokladu, že podnik patří do jedné z předem specifikovaných populací? Vycházel z dat za roky 1970 – 1976, přičemž pozoroval 105 úpadkových a 2058 neúpadkových podniků. Ve své studii z roku 1980 narazil na několik důležitých poznatků. Pravděpodobnost úpadku ovlivňují čtyři statisticky významné faktory: velikost podniku, finanční struktura, výkonnost a běžná likvidita. Dále podle Ohlsona předchozí modely přeceňují své predikční schopnosti z důvodu využívání dat z výkazů zveřejněných až po datu úpadku, což znamená jednodušší předpověď úpadku. Ve své studii Ohlson prezentoval tři modely, přičemž

vycházel z devíti nezávislých proměnných. První model předpovídá úpadek do jednoho roku, druhý do dvou let (za předpokladu, že u podniku nebyl prohlášen úpadek v předcházejícím období) a třetí model predikuje úpadek do jednoho až dvou let (Ohlson, 1980).

3.5. Omezení a problémy predikčních modelů

Profilová analýza, reprezentující možnost predikce na základě poměrových ukazatelů, dokáže stanovit existenci rozdílu mezi úspěšnými a neúspěšnými podniky, avšak již není schopna stanovit velikost daného rozdílu. Koncentruje se totiž na jediný bod rozdělení ukazatele, na průměrnou hodnotu. Bez dodatečné znalosti rozptýlení okolo daného bodu nelze vyjádřit smysluplný závěr ohledně predikční schopnosti ukazatele (Beaver, 1966).

V současné době jsou ekonomické cykly realitou. Predikční modely předpokládají neměnné váhy jednotlivých ukazatelů. Při tvorbě modelu např. v období ekonomického boomu, koeficienty již nejspíše nebudou stejně platné v situaci ekonomického poklesu. Jako další omezující faktor lze uvažovat situaci, kdy vzorky pro tvorbu modelů jsou příliš homogenní, zatímco reálné charakteristiky (období, odvětví, země) podniků při aplikaci mohou být mnohem více nestejnorodé. Problém je spatřován i v neexistenci přesvědčivé teorie, vysvětlující neúspěch podniků. Zásadní omezení v podobě existence podvodného účetnictví rovněž významným způsobem snižuje predikční schopnost těchto modelů (Fight, 2004).

Dugan a Grice (2001) zkoumali možnost zobecnění Zmijewskiho a Ohlsonova modelů. Vzorky úspěšných a neúspěšných firem k nim byly proporcionální, avšak časové období, odvětví a finanční podmínky byly zvoleny odlišně. Zjistili pokles úspěšnosti predikce při aplikaci na alternativní vzorky. To znamená, že vztah mezi poměrovými ukazateli a finanční tísní se v čase mění. V jejich studii byl Zmijewskiho model oproti modelu Ohlsona značně přesnější, pokud jde o schopnost klasifikace. Závěrem je tedy poznatek, že aplikace modelu na data z jiného časového období a odvětví, než na kterých byl daný model vytvořen, může ústít ve významný pokles jeho predikční přesnosti. Rovněž některé modely mohou být obecně užitečnější při využití k předpovědi finanční tísně, nežli přímo úpadku (Grice&Dugan, 2001).

4. Klasifikační metody

Třetí kapitola je věnována popisu klasifikačních metod. Po jejich stručné charakteristice a zmínění procesu tvorby a druhů klasifikačních modelů se další část zabývá popisem těch metod, vztahujících se k praktické části této práce – diskriminační analýzy a logistické regrese. Kapitola rovněž obsahuje problematiku vyhodnocení kvality vytvořeného modelu, resp. schopnosti správně klasifikovat vybraný podnik, tedy nedílnou součást celého postupu vytvoření modelu.

4.1. Charakteristika klasifikačních metod

Problematika statistických klasifikačních metod se řadí k vícerozměrným statistickým metodám. Základem je množina objektů, které lze na základě určitých statistických znaků zařadit do dvou či více disjunktních skupin (tříd). Cílem klasifikačních modelů je následně pomocí klasifikačních pravidel optimálně zařadit zkoumaný objekt. To znamená klasifikovat ho do správné skupiny, resp. maximalizovat pravděpodobnost zařazení i -tého objektu do i -té třídy (Barvenčík, 2010).

Ve spojení s klasifikačními metodami se v literatuře objevují dva pojmy – učení s učitelem a učení bez učitele. Podstatou učení s učitelem, ze kterého obecně pojem klasifikace vychází, je znalost příslušnosti jednotlivých objektů do předem známých skupin. Pomocí cílového modelu potom dochází ke klasifikaci objektů, u nichž není známa skupinová příslušnost, do jedné z existujících skupin. Naopak při učení bez učitele vstupní data neposkytují informace o skupinové příslušnosti dílčích objektů. Počet skupin většinou rovněž není předem znám (Zdeněk, 2012).

Postup klasifikace se odvíjí od jistých předpokládaných vlastností objektů klasifikace, například zda má náhodný vektor normální rozdělení. V tomto případě se jedná o parametrické klasifikační metody. O neparametrických klasifikačních metodách lze potom hovořit v podmínkách neznalosti rozdělení náhodného vektoru (Meloun & Mílitký, 2006).

4.2. Tvorba a druhy klasifikačních modelů

Samotný proces klasifikace obsahuje dvě části, a sice učení a vlastní klasifikaci. Proces učení představuje tvorbu klasifikačního modelu, který je na základě trénovacích dat schopen klasifikovat určená data. Vlastní klasifikací se rozumí aplikace vytvořeného

modelu na nová data a jejich zařazení do předem stanovených skupin, resp. tříd (Rychlý, 2003).

Tvorba modelu se skládá ze dvou kroků – trénování a následné testování. Trénování představuje odvození klasifikačního modelu za využití trénovacího souboru. Závislá proměnná nabývá několika diskrétních úrovní, určujících příslušnost pozorování (skupinu). Jako nezávisle proměnné zde lze chápat jednotlivá kritéria, jejichž hodnoty jsou obsaženy ve vektorech dílčích pozorování. Následně přichází na řadu testování, při kterém dochází ke zhodnocení kvality zkonstruovaného modelu. Při testování je tedy ověřováno, do jaké míry se shodují apriorní a odhadnuté klasifikace. V případě dostatečné shody lze tento model aplikovat na nová pozorování (Zdeněk, 2012).

Pro věrohodnější popis reality, charakteristické nekonečně mnoha dimenzemi, a pro přesnější kvantitativní uvažování nepostačují pouze jednorozměrné metody analýzy dat. Zavedení počítačů a vznik vhodných programů umožnilo širší používání a další rozvoj metod vícerozměrné analýzy. Techniky vícerozměrné analýzy lze dělit podle vztahů mezi skupinami proměnných na metody externální, internální a strukturální analýzy.

Metody externální analýzy analyzují dvě skupiny proměnných, a sice počet a povahu vztahů mezi nimi. Mezi nejčastěji používané se řadí mnohonásobná regresní analýza. Spadá zde i logistická regrese jako jisté zobecnění lineární regresní analýzy. Dále do této skupiny metod patří diskriminační analýzy, víceúrovňové modelování, kanonická korelační analýza, vícerozměrná analýza rozptylu, techniky klasifikačních stromů nebo analýza historie událostí.

Metody internální analýzy se zabývají podobností proměnných, nacházejících se uvnitř jedné skupiny. Mezi tyto metody se řadí analýza hlavních komponent, shluková analýza, formy faktorové analýzy, analýza nejmenšího prostoru, korespondenční analýza, analýza latentních tříd či konfigurační četnostní analýza.

Metody strukturální analýzy podrobují zkoumání několik skupin proměnných a vztah mezi nimi. Zástupci této kategorie jsou analýza korelačních cest nebo lineární strukturální relační analýza (Hendl, 2006).

V průběhu historie vzniklo značné množství klasifikačních metod a přístupů k predikci finanční tísně, přičemž stále dochází k vývoji nových metod. V dalším textu budou vzhledem k cíli práce podrobeny detailnějšímu popisu pouze dvě metody – diskriminační analýza a logistická regrese.

4.3. Diskriminační analýza

Podstatou diskriminační analýzy je obecně klasifikace objektu do některé z existujících skupin, resp. tříd. V zásadě zkoumá závislost mezi určitým množstvím (p) nezávisle proměnných (diskriminátorů) a jednou závisle proměnnou kvalitativního charakteru. Na základě hodnot diskriminátorů jsou objekty na počátku zařazeny do primárních tříd. Dále následuje proces klasifikace dosud nezařazených objektů do jedné z těchto tříd dle největší míry podobnosti, např. za využití nejmenší Mahalanobisovy vzdálenosti (Meloun & Militký, 2006).

V souvislosti se zařazením do skupin lze spatřovat dva hlavní cíle, resp. úhly pohledu. První je popis rozdělení na skupiny. Lineární funkce proměnných (diskriminační funkce) vysvětlují rozdílnost mezi dvěma či více skupinami. Úlohou této popisné diskriminační analýzy⁴ je identifikace relativního příspěvku určitého počtu proměnných (a jejich lineární kombinace) k optimální charakteristice odlišností skupin. Druhému cíli náleží predikce a přiřazení jednotlivých pozorování do předem daných skupin prostřednictvím klasifikační funkce⁵ (Rencher, 2002).

4.3.1. Kanonická diskriminační analýza

Kanonická diskriminační analýza plní úlohu posuzování schopnosti daných kvantitativních proměnných oddělit (rozlišit) jednotlivé skupiny (třídy) jednotek v souboru. Fisherovu koncepci diskriminační analýzy lze chápat jako snahu o nalezení lineární kombinace p pozorovaných proměnných, tzn. $\mathbf{Y} = \mathbf{v}^T \mathbf{x}$, kde $\mathbf{v}^T = [v_1, v_2, \dots, v_p]$. Přičemž by tato lineární kombinace měla separovat daných K skupin lépe než jiná, a to za co nejmenší vnitroskupinové variability a co největší meziskupinové variability.

Celková variabilita původních proměnných odpovídá čtvercové matici $\mathbf{T}$, typu $p \times p$:

$$\mathbf{T} = \sum_{k=1}^K \sum_{i=1}^{n_k} (\mathbf{x}_{ki} - \bar{\mathbf{x}})(\mathbf{x}_{ki} - \bar{\mathbf{x}})^T$$

Symbol K odpovídá počtu skupin a symbol n představuje rozsah souboru, resp. počet podniků. Celková variabilita se rovná součtu vnitroskupinové variability, vyjádřené maticí $\mathbf{E}$, a meziskupinové variability, ztvárněné maticí $\mathbf{B}$. Tedy $\mathbf{T} = \mathbf{E} + \mathbf{B}$, přičemž:

⁴ Odpovídá kapitola 4.3.1. Kanonická diskriminační analýza

⁵ Odpovídá kapitola 4.3.2. Klasifikační diskriminační analýza

$$\mathbf{E} = \sum_{k=1}^K \sum_{i=1}^{n_k} (x_{ki} - \bar{x}_k)(x_{ki} - \bar{x}_k)^T$$

$$\mathbf{B} = \sum_{k=1}^K \sum_{i=1}^{n_k} (x_k - \bar{x})(x_k - \bar{x})^T = \sum_{k=1}^K n_k (\bar{x}_k - \bar{x})(\bar{x}_k - \bar{x})^T$$

Míru vnitroskupinové a meziskupinové variability pro nově vzniklou veličinu Y vyjadřují součty čtverců $Q_E(Y)$ a $Q_B(Y)$, kde $Q_E(Y) = \mathbf{v}^T \mathbf{B} \mathbf{v}$ a $Q_B(Y) = \mathbf{v}^T \mathbf{E} \mathbf{v}$. Nejmenší vnitroskupinové a největší meziskupinové variability dosahuje veličina Y v případě maximalizace tzv. Fisherova diskriminačního kritéria λ , které je vyjádřeno následujícím podílem:

$$\lambda = \frac{Q_B(Y)}{Q_E(Y)} = \frac{\mathbf{v}^T \mathbf{B} \mathbf{v}}{\mathbf{v}^T \mathbf{E} \mathbf{v}}$$

Za účelem stanovení veličiny $Y = \mathbf{v}^T \mathbf{x}$, postihující rozdílnosti mezi jednotlivými skupinami, je nutné stanovit takové prvky vektoru $\mathbf{v}$, aby maximalizoval zmíněné diskriminační kritérium λ . Tento problém lze řešit následovně:

$$(\mathbf{B} - \lambda \mathbf{E}) \mathbf{v} = 0, \text{ resp. } (\mathbf{E}^{-1} \mathbf{B} - \lambda \mathbf{I}) \mathbf{v} = 0, |\mathbf{E}| \neq 0$$

Z charakteristické rovnice $|\mathbf{E}^{-1} \mathbf{B} - \lambda \mathbf{I}|$ vyplývá R nenulových řešení - charakteristická uspořádaná čísla $\lambda_{(1)}, \lambda_{(2)}, \dots, \lambda_{(R)}$ matice $\mathbf{E}^{-1} \mathbf{B}$. Největšímu z těchto čísel, tedy $\lambda_{(1)}$, lze přiřadit vektor $\mathbf{v}_1$. Tento vektor maximalizuje dané Fisherovo diskriminační kritérium λ . Tato charakteristická rovnice však pouze určuje poměr mezi prvky vektoru $\mathbf{v}_1$. Pro získání konkrétních hodnot těchto prvků (koeficientů lineární kombinace) je nutné tento vektor např. normovat na jednotkovou délku. Nechť dojde ke zvolení vektoru $\mathbf{v}_1$ způsobem, že:

$$\mathbf{v}_1^T \mathbf{E} \mathbf{v}_1 = 1, \text{ případně } \frac{1}{n-K} \mathbf{v}_1^T \mathbf{E} \mathbf{v}_1 = 1$$

potom bude součet čtverců (popřípadě rozptyl), který vyjadřuje vnitroskupinovou variabilitu veličiny $Y_1 = \mathbf{v}_1^T \mathbf{x}$ jednotkový. Následující rovnice zachycuje maximum daného diskriminačního kritéria:

$$\lambda_{(1)} = \mathbf{v}_1^T \mathbf{B} \mathbf{v}_1 = Q_B(Y_1), \text{ popřípadě } \lambda_{(1)} = \frac{1}{n-K} \mathbf{v}_1^T \mathbf{B} \mathbf{v}_1 = \frac{Q_B(Y_1)}{n-K}$$

Meziskupinová variabilita veličiny Y_1 je tedy vyjádřena charakteristickým číslem $\lambda_{(1)}$, přičemž lineární kombinací Y_1 lze rozumět první diskriminant či první kanonickou proměnnou.

V situaci třídění souboru jednotek pouze do dvou skupin bude pro splnění požadavku úplného zachování odlišnosti mezi jednotlivými skupinami postačovat jediný diskriminant (Hebák, 2007a).

Případu dvou výsledných skupin odpovídá i praktická stránka této práce, tudíž v teoretické části již nebudou dále vymezeny okolnosti třídění do tří a více skupin.

4.3.2. Klasifikační diskriminační analýza

Předchozí kapitola byla věnována deskripci kanonické diskriminační analýzy, jež lze označit spíše jako nástroj popisu rozdílů mezi jednotlivými skupinami. Naproti tomu klasifikační diskriminační analýza se těší častějšímu používání. Jak již lze vyvodit z názvu, účelem je klasifikace pozorování neznámého původu do jedné z předem stanovených skupin (tříd). Diskriminační kritérium pro toto zařazení představuje funkce primárních proměnných, která byla odhadnuta dle výběrového souboru pozorování, charakteristických znalostí příslušnosti ke skupině (Hebák, 2007a).

Vzhledem k praktickému zaměření této práce bude tato teoretická kapitola zpracována v rámci diskriminace mezi pouze dvěma skupinami.

Uvažování v rámci naplnění některých základních předpokladů je důležitou součástí dalšího postupu. Náhodný vektor $\mathbf{x}^T = [X_1, X_2, \dots, X_p]$ má ve výchozích dvou skupinách vícerozměrné normální rozdělení. Vektory středních hodnot tohoto rozdělení jsou označeny $\boldsymbol{\mu}_1$ a $\boldsymbol{\mu}_2$. Dále se předpokládají shodné kovarianční matice $\boldsymbol{\Sigma}$. Pokud vektor parametrů označíme $\mathbf{v}$, potom $\mathbf{v}^T \mathbf{x}$ představuje zápis lineární kombinace veličin z vektoru $\mathbf{x}$. Nyní lze vyjádřit Fisherovo diskriminační kritérium: $(\mathbf{v}^T \boldsymbol{\mu}_1 - \mathbf{v}^T \boldsymbol{\mu}_2) / \sqrt{\mathbf{v}^T \boldsymbol{\Sigma} \mathbf{v}}$. Toto kritérium je maximalizováno vektorem parametrů $\mathbf{v} = a \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)$, kde a vyjadřuje libovolnou konstantu. V případě zvolení stejně podmínky jako v předchozí kapitole, tedy $\mathbf{v}^T \boldsymbol{\Sigma} \mathbf{v}$, lze uvažovat tento vzorec:

$$a = [(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)]^{-1/2}$$

Diskriminační funkce má následující tvar:

$$\mathbf{x}^T \mathbf{v} = \mathbf{x}^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)$$

V uvažovaných skupinách je tato funkce charakteristická normálním rozdělením se středními hodnotami $\boldsymbol{\mu}_1^T \mathbf{v} = \boldsymbol{\mu}_1^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)$ a $\boldsymbol{\mu}_2^T \mathbf{v} = \boldsymbol{\mu}_2^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)$, přičemž jejich vzdálenost představuje Mahalanobisovu vzdálenost těchto dvou skupin a určí se podle vztahu

$$(\boldsymbol{\mu}_1^T \mathbf{v} - \boldsymbol{\mu}_2^T \mathbf{v}) = [(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)]$$

a střed mezi těmito dvěma středními hodnotami lze zjistit následovně:

$$c = \frac{1}{2}(\boldsymbol{\mu}_1^T \mathbf{v} - \boldsymbol{\mu}_2^T \mathbf{v}) = \frac{1}{2}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)$$

Nyní přichází na řadu formulace diskriminačního pravidla. Klasifikovaná jednotka má blíže k jedné z daných dvou skupin v situaci, kdy $\mathbf{x}^T \mathbf{v} > c$. Ke druhé skupině má blíže v opačném případě. Diskriminační pravidlo má tuto formulaci:

$$\mathbf{x}^T \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) > \frac{1}{2}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \quad \text{u první skupiny}$$

$$\mathbf{x}^T \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) < \frac{1}{2}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^T \boldsymbol{\Sigma}^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2) \quad \text{u druhé skupiny}$$

Nechť platí předpoklad vícerozměrné normality a společné kovarianční matice. Značení $f_1(\mathbf{x})$ a $f_2(\mathbf{x})$ odpovídají hustotám pravděpodobnosti pro vícerozměrná náhodná rozdělení uvažovaných dvou skupin. Klasifikace zkoumané jednotky s pozorováním $\mathbf{x}$ dle tohoto kritéria do první skupiny nastane v případě, že $f_1(\mathbf{x}) / f_2(\mathbf{x}) > 1$. Jinak zařazuje kritérium danou jednotku do druhé skupiny. Zmíněné kritérium navíc uvažuje, že skupiny mají v dané populaci stejné zastoupení, a tedy stejně pravděpodobné mylné zařazení jednotky do nesprávné skupiny. Skupiny však mohou nabývat odlišné velikosti. Vědění, že jednu skupinu tvoří $100\pi_1\%$ jednotek populace a $100\pi_2\%$ druhou skupinu, přičemž $\pi_1 + \pi_2 = 1$, představuje důležitou informaci při klasifikaci jednotek, jejichž původ není znám, již v momentu neznalosti dalších informací. Symboly π_1 a π_2 značí apriorní pravděpodobnosti, že zkoumaná jednotka patří do jedné z daných skupin. Hodnoty p veličin, které jsou známé u vybrané jednotky, poskytují informace pro úvahu podmíněných aposteriorních pravděpodobností určité klasifikace. Zařazení jednotky neznámého původu následně proběhne do skupiny, jejíž aposteriorní pravděpodobnost je vyšší. V případě platnosti vztahu $f_1(\mathbf{x}) / f_2(\mathbf{x}) > \pi_2 / \pi_1$ dochází ke klasifikaci do první skupiny.

Po abstrahování od případné neekvivalentnosti důsledků možné chybné klasifikace vyplývají dva základní přístupy, odlišující se uvažováním či neuvažováním apriorních pravděpodobností. Výsledkem zmíněných klasifikačních kritérií jsou následující lineární diskriminační funkce:

$$\mathbf{x}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_1 - \frac{1}{2} \boldsymbol{\mu}_1^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_1 + \ln \pi_1 = \mathbf{x}^T \mathbf{v}_1 + \mathbf{c}_1 + \ln \pi_1 \quad \text{u první skupiny}$$

$$\mathbf{x}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_2 - \frac{1}{2} \boldsymbol{\mu}_2^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_2 + \ln \pi_2 = \mathbf{x}^T \mathbf{v}_2 + \mathbf{c}_2 + \ln \pi_2 \quad \text{u druhé skupiny}$$

$$\text{kde} \quad \mathbf{x}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_k = \mathbf{x}^T \mathbf{v}_k \quad \text{a} \quad \frac{1}{2} \boldsymbol{\mu}_k^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}_k = \mathbf{c}_k, \quad k=1,2$$

Jednotka podlehe zařazení do takové skupiny, která nabývá větší hodnoty lineární diskriminační funkce.

V případě vyvrácení předpokladu, že kovarianční matice jsou shodné, optimálním klasifikačním pravidlem by byla diskriminační funkce kvadratická (Hebák, 2007a).

4.3.3. Test významnosti ukazatelů

Test významnosti plní účel stanovení diskriminantů, způsobilých k odlišení jednotlivých skupin. Fisherovo diskriminační kritérium $\lambda = \mathbf{v}^T \mathbf{B} \mathbf{v} / \mathbf{v}^T \mathbf{E} \mathbf{v}$ je maximalizováno v rámci λ_1 , tedy největšího charakteristického čísla z matice $\mathbf{E}^{-1} \mathbf{B}$. Necht' existuje K skupin a jejich vektory středních hodnot. Potom lze uvažovat test shody těchto vektorů, vycházející z Wilkovy statistiky Λ s rozdělením $\Lambda_{p,K-1,n-K}$:

$$\Lambda_1 = \prod_{i=1}^R \frac{1}{1 + \lambda_i}$$

Nyní je možné formulovat testovací kritérium V_1 s χ^2 rozdělením a $p(K-1)$ stupni volnosti:

$$V_1 = \left[n - 1 - \frac{1}{2}(p + K) \right] \sum_{i=1}^R \ln(1 + \lambda_i)$$

Testová statistika Λ_1 testuje významnost všech charakteristických čísel $\lambda_{(1)}, \lambda_{(2)}, \dots, \lambda_{(R)}$. Jestliže dojde k zamítnutí nulové hypotézy, že $\lambda_{(1)}, \lambda_{(2)}, \dots, \lambda_{(R)}$ jsou nulová, nejméně jedno charakteristické číslo se potom významně vzdaluje od nuly, tudíž diskriminační kritérium lze označit za významné. Další postup, test významnosti $\lambda_{(2)}, \lambda_{(3)}, \dots, \lambda_{(R)}$, respektive ověření hypotézy jejich rovnosti nule, se provede na základě testovacího kritéria V_2 ,

$$V_2 = \left[n - 1 - \frac{1}{2}(p + K) \right] \sum_{i=2}^R \ln(1 + \lambda_i)$$

kterému je opět vlastní přibližně χ^2 rozdělení s $(p-1)$ ($K-2$) stupni volnosti. Případné zamítnutí nulové hypotézy odpovídá závěru, že přinejmenším λ_2 je významné. V tomto duchu je postupováno i nadále, testováním každého λ_i , dokud test neuspěje se zamítnutím nulové hypotézy (Hebák, 2007a; Rencher, 2002).

4.3.4. Krokový výběr proměnných

V mnoha případech je k dispozici velké množství závisle proměnných, přičemž je důležité najít takové, které jsou pro účel separace do skupin redundantní. První metoda (tzv. forward selection method) začíná jednou proměnnou, která sama maximálně separuje dané skupiny. V každém kroku se přidává další proměnná, maximálně přispívající ke skupinové separaci. Při druhé metodě (tzv. backward elimination) se naopak začíná se všemi proměnnými. Následně dochází v každém kroku k odebrání proměnné, která přispívá nejméně. Metoda krokového výběru (tzv. stepwise selection) je kombinací dvou předešlých přístupů. Během každého kroku se přezkoumává možnost existence redundantní proměnné, přidané v předchozích krocích a vzniklé reakci na přítomnost nově přidané proměnné (Rencher, 2002).

Krokový výběr proměnných lze provést na základě Wilksova kritéria, definovaného jako $\Lambda = \frac{|E|}{|E+B|}$. Zamítnutí nulové hypotézy H_0 o shodě středních hodnot nastává, pokud $\Lambda \leq \Lambda_{\alpha, p, n-K, K-1}$, tedy v případě malých Λ . Statistiku Λ aproximuje následující F statistika:

$$F = \frac{1 - \Lambda}{\Lambda} \frac{n - K - p}{K - 1}$$

Tato statistika je charakteristická F rozdělením s $K-1$ a $n-K$ stupni volnosti, zůstávající pro všechny kroky stejné. V dalších krocích se namísto F statistiky postupuje užitím parciálního Λ ,

$$\Lambda = \frac{\Lambda_p}{\Lambda_{p-1}}$$

přičemž Λ_{p-1} představuje hodnotu Wilksova kritéria, než je přidána další proměnná. Λ_p značí hodnotu kritéria po přidání dané proměnné. Pro všechny kroky lze uvažovat následující pravidla. Z modelu bude odebrána proměnná, která vykazuje nejnižší hodnotu F a ta není větší nebo rovna F hodnotě pro vyřazení. Do modelu se zařadí proměnná, nabývající nejvyšší hodnoty F, jestliže tato hodnota není nižší než F hodnota pro vstup. Proces končí, nelze-li již žádnou proměnnou zařadit nebo vyřadit (Havránek & Vorlíček, 1980; Rencher, 2002).

4.4. Logistická regrese

Metoda regresní analýzy, pracující s úvahou nespojitě závislé (predikované) proměnné, se nazývá logistická regrese. Vznikla již v šedesátých letech pro situaci

binární (alternativní, dichotomické) závisle proměnné, tedy že může nabývat pouze dvou hodnot. Avšak je vhodné zdůraznit, že tato metoda není omezená výlučně na binární případy. Logistická regrese předpovídá pravděpodobnost určitého jevu, který buď nastal, nebo nenastal (Meloun & Militký, 2006; Řeháková, 2000).

Alternativní závisle proměnná Y nabývá hodnoty 1 (resp. $Y=1$), jestliže nastal jev J . Hodnota proměnné Y je naopak rovna nule (resp. $Y=0$), pokud jev J nenastal. Předmětem soustředění se stává závislost hodnot pravděpodobnosti, vyjádřené $P(Y=1)$, na okolnostech daných několika nezávisle proměnnými. Výraz lineárního regresního modelu $\beta_0 + \sum \beta_i x_i$ představuje očekávanou (průměrnou) hodnotu závisle proměnné Y , nabývající hodnot mínus nekonečno až nekonečno. Při úvaze alternativní proměnné Y potom tato průměrná hodnota značí pravděpodobnost události $Y=1$, tudíž lze pro $P(Y=1)$ uvažovat regresní model. Přílišná omezenost intervalu hodnot pravděpodobnosti 0 až 1 pro výraz $\beta_0 + \sum \beta_i x_i$ odůvodňuje záměnu pojmu pravděpodobnosti jevu za šanci jevu. Hodnota šance daného jevu, podíl $P(Y=1)/[1-P(Y=1)]$, se pohybuje v intervalu nula až nekonečno. Na základě transformace prostřednictvím přirozeného logaritmu šance vzniká pojem logit, definovaný vztahem:

$$\text{logit}(Y) = \ln \frac{P(Y=1)}{1-P(Y=1)}$$

Hodnoty logitu potom patří do intervalu mínus nekonečno až nekonečno, který odpovídá intervalu hodnot výrazu $\beta_0 + \sum \beta_i x_i$. Za použití logitu jako závisle proměnné vzniká následující rovnice:

$$\text{logit}(Y) = \beta_0 + \sum_i \beta_i x_i$$

Využitím exponenciální funkce lze převést logit zpět na šanci ($Y=1$) a tu potom zpět na pravděpodobnost následovně:

$$\text{šance}(Y=1) = \exp[\text{logit}(Y)]$$

$$P(Y=1) = \frac{\text{šance}(Y=1)}{1 + \text{šance}(Y=1)} = \frac{\exp(\beta_0 + \sum_i \beta_i x_i)}{1 + \exp(\beta_0 + \sum_i \beta_i x_i)}$$

Vhodnost užití pravděpodobností a šancí před vyjádřením prostřednictvím logitu vyplývá z interpretační jednoduchosti (Hebák, 2007b; Hendl, 2006; Řeháková, 2000).

4.4.1. Regresní koeficienty a jejich významnost

Logistický koeficient β_k představuje změnu logitu za předpokladu, že se hodnota nezávisle proměnné X_k změní o jednotku, přičemž hodnoty dalších nezávisle proměnných zůstanou beze změny. Za těchto presumpcí reprezentuje výraz $\exp(\beta_k)$ násobek, na základě kterého se změní šance. V případě, že $\beta_k > 0$, dochází ke zvětšení šance. Opak nastává v případě $\beta_k < 0$. Při nulové hodnotě β_k zůstává šance nezměněna (Řeháková, 2000).

Při testování statistické významnosti regresních koeficientů se vychází z hypotézy tvrdící jejich nenulovost, přičemž v případě velkých výběrů se používá tzv. Waldovo testové kritérium. Jeho pomocí dochází k vyčíslení významnosti dané nulové hypotézy v případě odhadů jednotlivých regresních koeficientů. Waldova statistika je charakteristická χ^2 rozdělením s jedním stupněm volnosti (Meloun & Militký, 2006).

4.4.2. Hodnocení logistického modelu

Použití statistiky -2LL (-2 log likelihood) s asymptotickým rozdělením χ^2 představuje jednu z možností, jak ohodnotit kvalitu vytvořeného logistického regresního modelu. K horší predikci závisle proměnné dochází v případě větších hodnot této statistiky. Prvně se zjišťuje hodnota statistiky v případě modelu, obsahujícího pouze konstantu α . Teprve potom dochází ke stanovení hodnoty u modelu, který zahrnuje danou skupinu K nezávisle proměnných. Rozdílem je tzv. χ^2 modelu, poskytující test zmíněné hypotézy o nulové hodnotě regresních koeficientů. K zamítnutí této hypotézy dochází v situaci, kdy výsledná hladina významnosti vychází menší nebo rovna zvolené hladině významnosti (p-value), obvykle zvolené ve výši 0,05.

Jako druhý způsob hodnocení modelu lze zmínit použití koeficientu determinace R^2 . Tento koeficient, vynásobený stem, vyjadřuje procento variability ve vysvětlované proměnné, které připadá na příslušné vysvětlující proměnné.

Třetí variantou posouzení kvality daného modelu je test dobré shody, resp. shody zvolených dat a regresního modelu. Patříčně velký výběrový soubor představuje základní podmínku získání smysluplného výsledku. Datový soubor se na základě určitého kritéria dělí do deseti zhruba stejně obsáhlých skupin. V každé takové skupině dochází ke zjištění očekávaného a skutečného počtu případů, u nichž daný jev J nastal nebo nenastal (Řeháková, 2000).

Mezi možnosti ohodnocení modelu patří i použití klasifikační tabulky. Metoda bude popsána v kapitole 4.5. 1.

4.5. Hodnocení kvality modelu

Metoda Bootstraping pracuje s údaji výběrového rozložení odhadu daného parametru. Zmíněné údaje se získávají ze souboru dat, využitého k provedení prvního odhadu, přičemž dochází k opakovaným výběrům. Při opakovaném výběru dochází ke vzniku nového, avšak lehce odlišného, stejně rozsáhlého souboru. Podniky v novém souboru, získané náhodným výběrem, se zde mohou objevit vícekrát či naopak vůbec. Hodnocení modelu potom probíhá na základě nového souboru (Hendl, 2009; Ratner, 2012).

Jako další způsob hodnocení kvality modelu lze zmínit metodu Jackknife. Na rozdíl od předchozí metody, která provádí nový výběr z celého datového souboru, uvažuje tento přístup výběr pouze jednoho prvku ze souboru. Podle tohoto postupu vzniká n výběrů s $n-1$ prvky. Dále následuje výpočet rozptýlenosti a odhadů, přičemž odhad klasifikátoru nastává podle informací o všech jednotkách, kromě jedné. U této jednotky se následně posoudí správnost klasifikace.

Za účelem posouzení kvality modelu připadá rovněž v úvahu metoda křížového ověřování, jejímž zvláštním případem je zmiňovaná metoda Jackknife. Data se zde dělí na dvě nebo více částí. Daný model vzniká pro všechna uvažovaná data, avšak jedna část je vynechána. Pro nevynechanou část následuje zhodnocení účinnosti klasifikace, resp. chyby předpovědi (Hendl, 2009).

Resubstituce vychází z použití klasifikátoru pro třídění takových jednotek, na základě kterých byl získán. Důsledkem tohoto postupu je však podhodnocení chybovosti modelu. To vede k předpokladu horších výstupů u nových podniků v případě vysoké chybovosti modelu u jednotek použitých pro odvození.

Metoda rozdělení souboru rovněž patří do metod hodnocení modelu. Za základ lze považovat rozdělení datového souboru (podniků) na dvě části. Prostřednictvím první části dochází k odvození modelu, následně testovaného na datech druhé části. Pravděpodobnost myslné klasifikace je zde odhadnuta nestranně. Tuto výhodu stírá nevýhoda, spatřovaná v požadavku existence rozsáhlého datového souboru pro předpokládané oddělení části jednotek (Hebák, 2007a).

4. 5. 1. Klasifikační matice

Konstrukce klasifikační matice se jeví jako užitečný nástroj pro ohodnocení úspěšnosti vytvořeného modelu, respektive jeho schopnosti správně zařadit klasifikovanou jednotku do příslušné alternativní závisle proměnné. Porovnává skutečnou, předem známou skupinovou příslušnost s příslušností predikovanou daným modelem. Diagonála matice obsahuje počet správně klasifikovaných jednotek. Lze zjišťovat podíl jednotek se správnou nebo špatnou klasifikací na celku.

Tabulka 1: Klasifikační matice⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace jako ⁽³⁾		Celkem ⁽⁴⁾
	1	0	
1	TP	FN	TP+FN
0	FP	TN	FP+TN
Celkem ⁽⁴⁾	TP+FP	FN+TN	n

⁽¹⁾ Classification matrix; ⁽²⁾ True group; ⁽³⁾ Classification as;

⁽⁴⁾ Total; Zdroj: vlastní zpracování

Číslo 1 značí pozitivní pozorování (např. bankrotní podniky), číslo 0 negativní pozorování (např. nebankrotní podniky).

TP (True Positives) vyjadřuje pozorování skutečně pozitivní, klasifikovaná správně jako pozitivní

FN (False Negatives) vyjadřuje pozorování skutečně pozitivní, klasifikovaná mylně jako negativní

FP (False Positives) vyjadřuje pozorování skutečně negativní, klasifikovaná mylně jako pozitivní

TN (True Negatives) vyjadřuje pozorování skutečně negativní, klasifikovaná správně jako negativní

4. 5. 2. ROC křivky

Grafy s křivkou ROC (receiver operating characteristics) jsou používány k organizaci klasifikačních modelů a vizualizaci jejich výkonnosti. Na vertikální osu tohoto dvojrozměrného grafu se nanáší senzitivita a na horizontální osu falešná pozitivita. V podstatě se jedná o pravděpodobnosti daného zařazení ve vztahu k množině všech uvažovaných dělicích bodů, přičemž každému z nich odpovídá jeden konkrétní bod na křivce ROC (Bortlíček, 2008; Fawcett, 2006).

Význam pojmů true positives (TP), false negatives (FN), false positives (FP) a true negatives (TN) byl popsán v předchozí kapitole, přičemž z nich vycházejí následující vzorce:


$$\text{Senzitivita}(\text{true positive rate, hit rate}) = TP / (TP + FN)$$

$$\text{Falešná pozitivita}(\text{false positive rate, false alarm rate}) = FP / (TN + FP)$$

$$\text{Specificita} = 1 - \text{falešná pozitivita} = TN / (FP + TN)$$

Křivka pokaždé prochází počátečním [0;0] a koncovým bodem [1;1], přičemž mezi nimi má neklesající tvar. Z teoretického pohledu zde existuje několik důležitých bodů. Bod [0;0] reprezentuje situaci, kdy nikdy nenastane pozitivní klasifikace. Opačným případem je bod [1;1], vyjadřující případ s pouze pozitivními zařazeními. Perfektní, tedy ve všech případech správná klasifikace, odpovídá bodu [0;1] a křivka zde kopíruje levý a horní okraj prostoru. Čím více dochází k vzájemnému překrývání hustot pravděpodobností, tím více se křivka přibližuje diagonále (viz obrázek 1). Bod nacházející se na diagonále lze označit za situaci, kdy dochází k náhodnému odhadu skupinové příslušnosti (Bortlíček, 2008; Fawcett, 2006).

Obrázek 1: Křivka ROC⁽¹⁾



⁽¹⁾ ROC Curve; Zdroj: Bortlíček (2008)

Plocha pod ROC křivou AUC (Area Under an ROC Curve) představuje kvantitativní index, často využívaný za účelem vyhodnocení více klasifikačních modelů. Lze tak

porovnat více ROC křivek, přičemž AUC umožňuje redukcí dílčí křivky do jedné konkrétní skalární hodnoty. Výsledek se bude vždy nacházet mezi 0 a 1, protože plocha pod křivkou je pouze částí celkové plochy daného čtverce. Náhodný odhad však tvoří diagonální přímku, jejíž AUC se rovná 0,5, tudíž reálný klasifikátor by měl vždy nabývat vyšší hodnoty (Bortlíček, 2008; Fawcett, 2006).

4.6. Výběr vzorku v kvantitativním výzkumu

Vybírání vzorků probíhá za účelem zobecnění celkové populace. Ideální případ je výběr vzorků, obvykle nějakým náhodným procesem, který patřičně reprezentuje danou populaci. Ve skutečnosti však často dochází k definici populace v podmínkách vzorků, spíše než naopak (Tabachnick & Fidell, 2007).

Základní metodu výběru vzorku představuje **prostý náhodný výběr**. Všechny jednotky daného souboru (populace) zde mají stejnou pravděpodobnost zvolení a zahrnutí do vzorku. Metoda vychází z tzv. opory výběru, tedy očíslovaného seznamu všech jednotek, patřících do základního souboru. Ke zvolení požadovaného počtu jednotek z opory výběru následně dochází prostřednictvím generátoru náhodných čísel. Pravděpodobnost zařazení dané jednotky do výběru vyjadřuje tzv. výběrový poměr, v jehož čitateli je rozsah výběru a ve jmenovateli velikost populace. Výběr lze uskutečnit s vrácením či bez vrácení prvku do základního souboru.

Stratifikovaný náhodný výběr může výzkumný pracovník použít například v situaci neproveditelnosti či přílišné nákladnosti provedení prostého náhodného výběru. Charakteristickým znakem této metody je možnost rozdělit danou populaci na více homogenních subpopulací, označovaných jako strata či vrstvy. K výběru potom dochází z každé z podskupin.

Vícestupňový shlukový výběr představuje další metodu na bázi náhodného prvku. Na základě náhodného výběru proběhne zvolení určitého vzorku (shluku) ze základního souboru. Z tohoto vzorku se stejným způsobem vybere určitý počet prvků, tvořících nový vzorek. Takto lze postupovat vícekrát, dokud nebude získán požadovaný výsledný vzorek.

Systematický výběr začíná číslováním všech prvků základního souboru, přičemž toto číslování by nemělo záviset na charakteristikách jednotlivých prvků. Následně dochází k systematickému výběru dle zvoleného způsobu (Hendl, 2009).

Kvótní výběr patří do metod záměrného výběru, který se od předchozích metod liší faktem, že do výběru nezasahuje náhoda, nýbrž např. úsudek výzkumníka. Podle určitých kontrolních znaků vznikají kvóty pro výběr, Kvóty by potom vyjadřovaly požadovaný počet jednotek určitých znaků či kategorií, zahrnutých do výběru. Nevýhoda metody je spatřována právě v subjektivní volbě jednotek z příslušných kategorií, kdy výzkumník může dávat přednost specifickým typům jednotek (Hendl, 2009; Chráska, 2007)

5. Metodika

Kapitola se věnuje metodické stránce praktické části diplomové práce. Na začátku dojde k definování cílů, a to jak hlavního, tak i dílčích. Potom následuje zmínění použitého softwaru. Rovněž budou vymezeny podniky v úpadku, vybrané podniky a jejich údaje, uvažované poměrové ukazatele a podrobnější popis dalších postupů.

5. 1. Cíle práce

Hlavním cílem je vytvořit vlastní modely pro předpověď úpadku podniku pomocí diskriminační analýzy a logistické regrese a vyhodnotit jejich vlastnosti. Další část předkládané diplomové práce lze rozdělit vymezením dílčích cílů:

a) Nejprve dojde ke klasifikaci vybraného vzorku podniků prostřednictvím již existujících modelů, přičemž bude posouzena jejich predikční spolehlivost v období jednoho až tří let před rokem úpadku. Následuje pokus o optimalizaci hodnoty dělicího bodu uvažovaných modelů za účelem zvýšení jejich spolehlivosti.

b) Nadále bude provedena jednorozměrná analýza, resp. profilová analýza. Ta spočívá ve výpočtu vybraných poměrových ukazatelů pro bankrotní i nebankrotní podniky a srovnání jejich vývoje za účelem zjištění významných rozdílů, signalizujících schopnost diskriminace.

c) Závěrečné vytvoření vlastních klasifikačních modelů využitím diskriminační analýzy a logistické regrese a ověření jejich spolehlivosti naplňuje hlavní cíl práce.

5. 2. Využívaný software

Pro provedení požadovaných výpočtů a eventuálních úprav byly využity dva programy, a sice Microsoft Excel 2007 od společnosti Microsoft a Statistica V12 od společnosti StatSoft (součástí společnosti Dell).

5. 3. Vymezení úpadkových podniků a volba vstupních dat

Za účelem získání požadovaných dat z účetních výkazů došlo k využití databáze, kterou poskytuje program Albertina. Jeho pomocí byly za období 2012-2015 nalezeny podniky, u kterých byl v daných letech prohlášen úpadek, a zároveň splňovaly zvolená kritéria velikosti. Vybrané subjekty odpovídají celoevropské definici malých a středních

podniků, konkrétně z hlediska počtu zaměstnanců, který se pohybuje v intervalu 50 až 250. Rovněž nejsou nikterak omezeny druhem odvětví, resp. oborem hlavní činnosti. Počet takto zvolených podniků je 29. Údaje z účetních závěrek byly získány vždy za období tří let před rokem, ve kterém došlo k prohlášení úpadku. Tedy úpadku v roce 2015 odpovídají výkazy z let 2014, 2013 a 2012, k úpadku v roce 2014 jsou uvažovány výkazy za roky 2013, 2012 a 2011 atd.

Soubor neúpadkových podniků taktéž poskytl program Albertina. Vzorek o stejném rozsahu, tedy 29 podniků, byl získán následovně. Každý z vybraných úpadkových subjektů pochází z odlišného odvětví (dle kódu NACE), na základě kterého mu byl přiřazen podnik neúpadkový. Neúpadkový soubor se tak vždy zúžil na podmnožinu, obsahující zástupce pouze z konkrétního odvětví. Z té byl následně proveden prostý náhodný výběr. Zvolené tři roky výkazů odpovídají rokům uvažovaným u úpadkových podniků daného odvětví.

K ověření, zda se vybrané úpadkové podniky skutečně nacházely v určitém roce v úpadku, či k eventuálnímu dohledání údajů z účetních závěrek, byl využit portál www.justice.cz.

5. 4. Výběr poměrových ukazatelů

V souvislosti s profilovou analýzou a hlavním cílem práce, tedy tvorbou vlastních modelů, muselo být vybráno množství poměrových ukazatelů. Jako zdroj inspirace posloužila nejenom odborná literatura, ale také ukazatele z již existujících, v literární části popsaných modelů. Na základě logické úvahy a dostupnosti dat zvoleného vzorku podniků došlo k výběru následujících 28 poměrových ukazatelů:

Ukazatele rentability

- dlouhodobá rentabilita, DLR, [(Rezervní fondy, nedělitelný fond a ostatní fondy ze zisku + Výsledek hospodaření minulých let + Výsledek hospodaření za účetní období) / Aktiva celkem]]
- míra zisku, VHD/A, (Výsledek hospodaření před zdaněním / Aktiva celkem)
- podíl výsledku hospodaření minulých let na aktivech, VHML/A, (Výsledek hospodaření minulých let / Aktiva celkem)
- podíl výsledku hospodaření před zdaněním na krátkodobých cizích zdrojích, VHD/KCK, (Výsledek hospodaření před zdaněním / Krátkodobé cizí zdroje)

- rentabilita celkového kapitálu, $VH\dot{U}D/A$, [(Výsledek hospodaření před zdaněním + Nákladové úroky) / Aktiva celkem]
- rentabilita dlouhodobých zdrojů, RDZ , [(Výsledek hospodaření za účetní období + Nákladové úroky) / (Vlastní kapitál + Dlouhodobé závazky)]
- rentabilita vlastního kapitálu, VH/VK , (Výsledek hospodaření za účetní období / Vlastní kapitál)
- rentabilita výnosů, VHD/V , (Výsledek hospodaření před zdaněním / Výnosy celkem)

(Knápková & Pavelková & Šteker, 2013; Sedláček, 2011)

Ukazatele účinnosti a vázanosti

- účinnost celkových aktiv, V/A , (Výnosy celkem / Aktiva celkem)
- vázanost krátkodobých závazků, KZ/V , (Krátkodobé závazky / Výnosy celkem)
- vázanost oběžných aktiv, OA/V , (Oběžná aktiva / Výnosy celkem)
- vázanost zásob, Z/V , (Zásoby / Výnosy celkem)

(Knápková & Pavelková & Šteker, 2013)

Ukazatele finanční stability

- běžná likvidita, $L3$, (Oběžná aktiva / Krátkodobé cizí zdroje)
- celková zadluženost, CK/A , (Cizí zdroje / Aktiva celkem)
- pohotová likvidita, $L2$, [(Krátkodobé pohledávky + Krátkodobý finanční majetek) / Krátkodobé cizí zdroje]
- peněžní likvidita, $L1$, (Krátkodobý finanční majetek / Krátkodobé cizí zdroje)
- koeficient samofinancování, VK/A , (Vlastní kapitál / Aktiva celkem)
- krátkodobá zadluženost, KCK/A , (Krátkodobé cizí zdroje / Aktiva celkem)
- krytí cizího kapitálu oběžným majetkem, OA/CK , (Oběžná aktiva / Cizí zdroje)
- podíl čistého pracovního kapitálu na aktivech, $\check{C}PK/A$, (Čistý pracovní kapitál / Aktiva celkem)
- podíl čistého pracovního kapitálu na výnosech, $\check{C}PK/V$, (Čistý pracovní kapitál / Výnosy celkem)

- úrokové krytí, $VHÚD/NÚ$, $[(Výsledek\ hospodaření\ před\ zdaněním + Nákladové\ úroky) / Nákladové\ úroky]$

(Knápková & Pavelková & Šteker, 2013; Sedláček, 2011)

Ukazatele nákladovosti

- mzdová nákladovost, OsN/V , (Osobní náklady / Výnosy celkem)
- nákladovost výkonové spotřeby, VS/V , (Výkonová spotřeba / Výnosy celkem)

(Marek, 2006)

Ukazatele založené na cash flow

- rentabilita aktiv z cash flow, CF/A , (Cash Flow / Aktiva celkem)
- stupeň oddlužení, CF/CK , (Cash Flow / Cizí zdroje)
- likvidita z cash flow, CF/KZ , (Cash Flow / Krátkodobé závazky)
- rentabilita výnosů z cash flow, CF/V , (Cash Flow / Výnosy celkem)

(Sedláček, 2011)

5. 5. Popis dílčích postupů

V souvislosti s prvním dílčím cílem bude provedeno zhodnocení klasifikační spolehlivosti stávajících modelů při aplikaci na zvolený vzorek 58 podniků. Dojde k výpočtu úspěšnosti a chybovosti pro úpadkové i neúpadkové subjekty, a to ve všech třech letech před rokem úpadku. Z důvodu umožnění jednoznačné klasifikace do příslušné binární proměnné bude provedena úprava původního klasifikačního pravidla rozdělením případné šedé zóny na polovinu. Zařazení proběhne do skupin nazvaných nebankrotní a bankrotní, přestože dané cílové intervaly jsou v jednotlivých modelech specifikovány různě. Charakteristiky skupin dílčích modelů jsou proto v textu vždy konkretizovány. Následuje sestavení klasifikačních matic pro každé ze tří období všech ověřovaných modelů. Procentní vyjádření spolehlivosti a chybovosti zde odpovídá podílu na celkovém počtu 58 podniků.

Jako reakce na hodnoty spolehlivosti navazuje pokus o jejich zvýšení prostřednictvím optimalizace hodnoty dělicího bodu. Při této snaze se bude postupovat tak, že každý z výsledků modelu pro daných 58 podniků za období jednoho roku před úpadkem bude zvážen jako možná prahová hodnota. Dojde tedy ke klasifikaci podniků

porovnáním výsledků modelů s 58 různými prahovými hodnotami. Výsledkem bude zjištění počtu správně a chybně klasifikovaných subjektů pro každou hodnotu. Vybraným dělicím bodem se stane takový, který vykáže minimální hodnotu celkové chybné klasifikace. Následuje ověření, zda nový dělicí bod vede ke zvýšení spolehlivosti bankrotního modelu. V tabulkách, zobrazujících srovnání úspěšnosti či chybovosti klasifikace s původním a novým dělicím bodem, bude použito následující označení: „true positives“ pro správně zařazené nebankrotní subjekty a „true negatives“ pro správně zařazené bankrotní subjekty, přičemž se jedná o podíl těchto klasifikací na celkovém vzorku 58 podniků.

Další kapitola se věnuje profilové analýze, jejíž provedení představuje druhý dílčí cíl této práce. Výpočet vybraných poměrových ukazatelů (viz předchozí kapitola) pro všechny subjekty lze označit za nezbytnou výchozí složku. Kalkulace proběhne pro každý z 29 bankrotních a 29 nebankrotních podniků zvlášť za daná tři období. Posléze bude provedeno zprůměrování hodnot dílčích ukazatelů v každém roce. To odpovídá 6 průměrům pro každý z klasifikátorů. Na základě těchto údajů dojde k vytvoření grafů, které umožňují vizuální vyhodnocení schopnosti diskriminace. Graf zobrazuje vývoj průměrných hodnot ukazatele za období tří let před úpadkem prostřednictvím dvou křivek – pro bankrotní a nebankrotní podniky zvlášť (tři body pro bankrotní, tři pro nebankrotní). Vodorovná osa značí počet let před úpadkem, svislá osa zachycuje průměrné hodnoty. Čím blíže k počátku se na vodorovné ose bod nachází, tím kratší časový horizont zbývá do úpadku. V grafech jsou rovněž zobrazeny chybové úsečky, odpovídající 95% intervalu spolehlivosti, daného vzorcem:

$$\bar{x} - t_{1-\frac{\alpha}{2}}(n-1) \frac{s}{\sqrt{n}} < \mu < \bar{x} + t_{1-\frac{\alpha}{2}}(n-1) \frac{s}{\sqrt{n}}$$

Kde: $\bar{x}$ = průměr, α = hladina významnosti, $t_{1-\alpha/2}(n-1)$ = 100 (1- α /2)% kvantil studentova rozdělení s n-1 stupni volnosti, s = směrodatná odchylka, μ = střední hodnota, a n = rozsah souboru (Meloun & Militký, 2006).

Při komentování výsledků bude z každé skupiny ukazatelů zobrazen graf pouze jednoho ukazatele, ostatní lze najít v příloze.

Ve vztahu k profilové analýze budou v programu Statistica provedeny testy shody středních hodnot dvou nezávislých vzorků (poměrových ukazatelů). Klasický studentův t-test má toto testové kritérium:

$$T = \frac{|\bar{x} - \bar{y}|}{\sqrt{(n_1 - 1)s_x^2 + (n_2 - 1)s_y^2}} \sqrt{\frac{n_1 n_2 (n_1 + n_2 - 2)}{n_1 + n_2}}$$

Kde: $\bar{x}$ = průměr výběru x, $\bar{y}$ = průměr výběru y, s = směrodatná odchylka a n = rozsah souboru (Meloun & Militký, 2006).

Rovněž budou v programu Statistica provedeny Levenovy testy shody rozptylů, které mají testovou statistiku:

$$W = \frac{(N - k) \sum_{i=1}^k n_i (z_{i.} - z_{..})^2}{(k - 1) \sum_{i=1}^k \sum_{j=1}^{n_i} (Z_{ij} - z_{i.})^2}$$

Kde k = počet výběrů, veličina $Z_{ij} = |Y_{ij} - y_i|$ charakteristické kritickou hodnotou Fisherova-Snedecorova rozdělení o k - 1 a N - k stupních volnosti (Hrochová, 2014).

Problematika diskriminační analýzy zahrnuje testy normality dat. K jejich výpočtům této práci poslouží Kolmogorovův-Smirnovův test, provedený rovněž v programu Statistica. Tento test je charakteristický testovacím kritériem D:

$$D_n = \max_x |F_n(x) - F(x)|$$

Kde F je distribuční funkce a F_n je empirická distribuční funkce (Anděl, 1998).

Ve stejném programu dojde k následné tvorbě modelů diskriminační analýzou a logistickou regresí, přičemž pro následné úpravy a konstrukci tabulek poslouží Microsoft Excel. Za účelem zohlednění navzájem korelovaných ukazatelů bude sestavena korelační matice. Z proměnných, vykazujících korelační koeficient (vzájemnou závislost) v absolutní hodnotě vyšší než 0,8, bude vždy vyřazena ta, která je pro klasifikaci méně statisticky významná (podle výsledků testů shody středních hodnot).

V případě diskriminační analýzy i logistické regrese bude uplatněna dopředná kroková metoda. Při jejím provedení u diskriminační analýzy bude za účelem hledání spolehlivějšího modelu zvyšována hladina významnosti p pro zahrnutí a vyjmutí proměnné z modelu vždy o hodnotu 0,05. Ověření klasifikační spolehlivosti nastane prostřednictvím metody resubstituce, při které se model aplikuje na vzorek subjektů, na základě kterých byl vytvořen. U diskriminační analýzy následuje pokus o optimalizaci

dělicího bodu, který by zvýšil primární spolehlivost. Postup bude stejný jako u kapitoly, zabývající se ověřením a optimalizací stávajících modelů. Pokus o nalezení vhodnějšího dělicího bodu pro model logistické regrese bude nejprve proveden totožným způsobem. Za možnou prahovou hodnotu však budou následně uvažovány taktéž výsledky modelu u daného vzorku podniků, tentokrát za časový horizont dvou a tří let před rokem, ve kterém byl prohlášen úpadek. Výsledkem je opět zjištění podílu mylně klasifikovaných subjektů pro každou hodnotu. Zvoleným dělicím bodem bude takový, který vykáže minimální hodnotu celkové chybovosti.

6. Ověření stávajících klasifikačních modelů

Vývoj ekonomických poměrů či technologických a dalších podmínek jednotlivých odvětví v čase nepochybně ovlivňuje působící subjekty. Dochází tedy ke změnám hospodaření a struktury výkazů podniků. Přitom se přirozeně utváří odlišné chápání hranic finanční stability a dalších faktorů, které ovlivňují finanční zdraví. Predikční modely tak mohou narážet na omezení v podobě rizika poklesu spolehlivosti z titulu aplikace modelu na jiná data, než na kterých byl model vytvořen. Cílem této kapitoly je zhodnocení predikční spolehlivosti již existujících modelů na uvažovaném vzorku 58 podniků.

Ověření budou podrobeny následující modely, blíže popsané v teoretické části: modely E. Altmana - Z' , Z'' , modely manželů Neumaierových - IN95, IN99, IN01, IN05, Tafflerovy modely – základní i modifikovaný a také Gurčíkův index. Původní Altmanův model Z pracuje s údaji z kapitálového trhu, tudíž zde není zahrnut. Posouzení spolehlivosti nastane za každé ze tří období před rokem úpadku. Téměř všechny modely pracují s tzv. šedou zónou. Za účelem jednoznačné klasifikace podle jednoho dělicího bodu došlo k jejich rozdělení na dvě poloviny, přičemž pozorování potom připadá bližší skupině.

6. 1. Altmanovo Z'

Před samotným výpočtem modelu došlo k již avizované úpravě klasifikačního pravidla. Šedá zóna byla rozdělena na polovinu a vznikl tak dělicí bod ve výši **2,065**. Hodnoty vyšší než 2,065 značí zařazení do skupiny nebankrotních (neúpadkových) subjektů. Pokud vyjde výsledné skóre modelu menší nebo rovno 2,065, dochází ke klasifikaci do třídy bankrotních (úpadkových) podniků.

Následuje posouzení spolehlivosti modelu Z' v jednotlivých letech, tedy jeden až tři roky před rokem úpadku. Výsledky jsou zobrazeny prostřednictvím klasifikačních matic, ve kterých dochází k absolutnímu i relativnímu vyjádření.

6. 1. 1. Altmanovo Z' - jeden rok před úpadkem

Z tabulky 2 lze vyčíst, že v případě schopnosti predikce úpadku jeden rok předem model dosahuje v souhrnu 86,206% úspěšnosti, resp. chybí v 13,794 % případů. Pravdivé či mylné zařazení nabývá u obou skupin shodných hodnot. Z 29 podniků v jedné skupině došlo k 25 správným klasifikacím a 4 mylným.

Tabulka 2: Klasifikační matice - Altmanovo Z' - 1 rok před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	25 (43,103 %)	4 (6,897 %)	29 (50 %)	43,103%	6,897%
Bankrotní ⁽⁵⁾	4 (6,897 %)	25 (43,103 %)	29 (50 %)	43,103%	6,897%
Celkem ⁽⁶⁾	29 (50 %)	29 (50 %)	58 (100 %)	86,206%	13,794%

⁽¹⁾ Confusion matrix - Altman's Z' - 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

6. 1. 2. Altmanovo Z' - dva roky před úpadkem

V situaci posouzení spolehlivosti modelu dva roky předem již došlo k poklesu. Absolutní i relativní výsledky zobrazuje tabulka 3. Celková spolehlivost poklesla o 8,620 % na 77,586 %, což představuje správnou klasifikaci 45 z 58 podniků. Mylná klasifikace proběhla u 13 z 58 případů, tedy v 22,414 %.

Tabulka 3: Klasifikační matice - Altmanovo Z' - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	22 (37,931 %)	7 (12,069%)	29 (50 %)	37,931%	12,069%
Bankrotní ⁽⁵⁾	6 (10,345 %)	23 (39,655%)	29 (50 %)	39,655%	10,345%
Celkem ⁽⁶⁾	28 (48,276 %)	30 (51,724%)	58 (100 %)	77,586%	22,414%

⁽¹⁾ Confusion matrix - Altman's Z' - 2 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

Taktéž nastala změna ve struktuře pravdivých a chybných zařazení v jednotlivých skupinách. Z počtu 29 skutečně nebankrotních zástupců jich model predikoval 22 (75,862 %) správně, resp. chyboval u 7 (24,138 %) případů. Bankrotní podniky zde klasifikoval se 79,310% úspěšností (23 z 29). Rovněž lze vidět, že větší úspěšnost má model při identifikaci ve skutečnosti bankrotních jednotek (podíl na celkovém počtu 58 je 39,655 % oproti 37,931 % nebankrotních).

6. 1. 3. Altmanovo Z' - tři roky před úpadkem

Tabulka 4 zachycuje skutečnost, že ve snaze včasného varování tři roky předem celková spolehlivost ještě více poklesla, a to o 3,449 procentních bodů na 74,137 % (43 z 58). Chyba tedy v souhrnu nastala u 25,863 % klasifikací (15 z 58).

Tabulka 4: Klasifikační matice - Altmanovo Z' - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	25 (43,103 %)	4 (6,897 %)	29 (50 %)	43,103 %	6,897 %
Bankrotní ⁽⁵⁾	11 (18,966 %)	18 (31,034 %)	29 (50 %)	31,034 %	18,966 %
Celkem ⁽⁶⁾	36 (62,069 %)	22 (37,931 %)	58 (100 %)	74,137 %	25,863 %

⁽¹⁾ Confusion matrix - Altman's Z' - 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

Nastala též změna struktury spolehlivosti v jednotlivých skupinách. Ze skutečně nebankrotních to bylo správných 25 z 29 případů (86,207 %). Naopak bankrotních subjektů model pravdivě zařadil pouze 18 z 29 (62,069 %). Je tedy zřejmé, že vyšší úspěšnost model vykazoval při klasifikaci skutečně nebankrotních podniků (43,103 % oproti 31,034 % bankrotních, relativně k celkovému počtu 58).

6. 1. 4. Altmanovo Z' - optimalizace dělicího bodu

Předcházející výsledky spolehlivosti Altmanova Z' neposkytují uspokojivé hodnoty. Průměrná chybovost ve výši 20,69 % naznačuje, že u každého pátého podniku proběhla mylná klasifikace. Z tohoto důvodu byl proveden pokus o optimalizaci dělicího bodu tak, aby se spolehlivost modelu zvýšila. Zvolený bod odpovídá tomu, který poskytuje minimální hodnotu celkové chybovosti. Dle zmíněného kritéria se jeví jako nejvhodnější bod **1,7**. Výsledky dílčích i celkových hodnot spolehlivosti v jednotlivých letech, jakož i jejich průměrné hodnoty při aplikaci původního a nového dělicího bodu, zachycuje tabulka 5.

Lze tedy poznamenat, že celková spolehlivost se u tohoto modelu nezměnila. Došlo pouze ke změně struktury klasifikací v jednotlivých skupinách. S novým dělicím bodem se snížil podíl správně zařazených ve skutečnosti bankrotních subjektů (z 37,93 % na 34,48 %), avšak spolehlivost klasifikace skutečně nebankrotních podniků vzrostla (ze 41,38 % na 44,83%). S prodlužující se dobou před úpadkem spolehlivost modelu rovněž klesá.

Tabulka 5: Optimalizace - Altmanovo Z' - spolehlivost ⁽¹⁾


Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	43,10%	43,10%	86,21%	39,66%	46,55%	86,21%
2	39,66%	37,93%	77,59%	36,21%	43,10%	79,31%
3	31,03%	43,10%	74,14%	27,59%	44,83%	72,41%
Průměr ⁽⁶⁾	37,93%	41,38%	79,31%	34,48%	44,83%	79,31%

⁽¹⁾ Optimization - Altman's Z' - Accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Original;

⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

Graf 1 zobrazuje velikosti dílčích druhů chybovostí (v procentech) v závislosti na hodnotě dělicího bodu. Na vodorovné ose jsou jednotlivé dělicí body, na svislé jim odpovídající procento chybné klasifikace.

Graf 1: Celkové i dílčí chybovosti Altmanova Z' pro jednotlivé dělicí body ⁽¹⁾



⁽¹⁾ Total and individual misclassification rates of Altman's Z' for particular thresholds; Horizontal axis = Threshold value; Vertical axis = Misclassification rate;

⁽²⁾ Total misclassification; Zdroj: vzorek podniků, vlastní zpracování

Chybovost celkem představuje součet mylně klasifikovaných skutečně nebankrotních (false negatives) a skutečně bankrotních (false positives) subjektů, přičemž se v těchto případech jedná o podíl na celém vzorku 58 podniků. Nejnižší hodnotě celkové

chybovosti odpovídají dva dělicí body (1,43 a 1,96), přičemž zvolený bod 1,7 představuje jejich aritmetický průměr. Z grafu je dále patrné, že s rostoucí hodnotou prahového bodu dochází k poklesu mylné klasifikace ve skupině skutečně bankrotních subjektů a k růstu počtu chybně zařazených skutečně nebankrotních subjektů

6. 2. Altmanovo Z''

Rovněž v tomto případě došlo k úpravě klasifikačního pravidla. Rozdělením šedé zóny vznikl prahový bod ve výši **1,85**. Subjekt bude zařazen do nebankrotní skupiny (mající uspokojivou finanční situaci) při výsledné hodnotě modelu větší než 1,85. Pokud naopak vyjde skóre daného podniku menší nebo rovno 1,85, nastává klasifikace do skupiny bankrotních případů (ohrožených vážnými problémy).

Klasifikace vzorku 58 entit dle upraveného pravidla opět proběhne ve všech třech obdobích před úpadkem. Ve srovnání s předchozím Altmanovým modelem, jak lze nadále vidět, dosahuje Z'' vyšší úspěšnosti v každém časovém horizontu.

6. 2. 1. Altmanovo Z'' - jeden rok před úpadkem

Výsledky zde prezentuje tabulka 6. Model dosahuje celkové spolehlivosti 87,931 % (51 z 58 entit správně klasifikovaných), což je oproti předchozímu modelu ve stejném období 1,725% zvýšení. Souhrnná chybovost nastává u 12,069 % případů (7 z 58).

Ze skupiny 29 skutečně nebankrotních zástupců jich tento model určil 22 pravdivě (75,862 %) a 7 mylně (24,138 %). U skutečně bankrotních podniků však byl 100% úspěšný. Rovněž při úvaze všech 58 jednotek byl tedy model úspěšnější u druhé skupiny (50 % proti 37,931 %).

Tabulka 6: Klasifikační matice - Altmanovo Z'' - 1 rok před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	<i>Nebankrotní</i> ⁽⁴⁾	<i>Bankrotní</i> ⁽⁵⁾			
<i>Nebankrotní</i> ⁽⁴⁾	22 (37,931 %)	7 (12,069 %)	29 (50 %)	37,931 %	12,069 %
<i>Bankrotní</i> ⁽⁵⁾	0 (0,000 %)	29 (50,000 %)	29 (50 %)	50,000 %	0,000 %
Celkem ⁽⁶⁾	22 (37,931 %)	36 (62,069 %)	58 (100 %)	87,931 %	12,069 %

⁽¹⁾ Confusion matrix - Altman's Z'' - 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

6. 2. 2. Altmanovo Z'' - dva roky před úpadkem

Tabulka 7 ukazuje, že oproti předchozímu modelu v tomto období predikce došlo ke značnému zvýšení úspěšnosti, a sice o 8,621 procentních bodů na 86,207 % (50 z 58). Z toho plyne mylná klasifikace v 13,793 % situací (8 z 58). Výsledkem srovnání spolehlivosti tohoto období s předchozím obdobím (jeden rok před úpadkem) byl mírný pokles o 1,724 procentních bodů.

Tabulka 7: Klasifikační matice - Altmanovo Z'' - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	22 (37,931 %)	7 (12,069 %)	29 (50 %)	37,931 %	12,069 %
Bankrotní ⁽⁵⁾	1 (1,724 %)	28 (48,276 %)	29 (50 %)	48,276 %	1,724 %
Celkem ⁽⁶⁾	23 (39,655 %)	35 (60,345 %)	58 (100 %)	86,207 %	13,793 %

⁽¹⁾ Confusion matrix - Altman's Z'' - 2 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

Taktéž nastala změna ve struktuře dílčích skupin. U skutečně nebankrotních podniků model správně zařadil 22 z 29 případů (75,862 %), což představuje 7 případů chybných (24,138 %). Bankrotní entity byly klasifikovány s 96,552% spolehlivostí (28 z 29). Na celkovém vzorku 58 podniků byl model opět úspěšnější u druhé skupiny (48,276 % bankrotních oproti 37,931 % nebankrotních).

6. 2. 3. Altmanovo Z'' - tři roky před úpadkem

Klasifikační matici zobrazuje tabulka 8. Také v tomto období při srovnání s prvním modelem bylo zaznamenáno zvýšení celkové spolehlivosti, a sice o 8,622 procentních bodů na 82,759 % (48 z 58). Vůči předcházejícímu období v rámci tohoto modelu došlo k poklesu úspěšnosti o 3,448 %. Chybovost je zde v součtu rovna 17,241 % (10 z 58).

Skutečně nebankrotní entity byly klasifikovány s 75,862% spolehlivostí (22 z 29) a skutečně bankrotní se spolehlivostí 89,655 % (26 z 29). Za toto období bylo tedy Altmanovo Z'' opět úspěšnější při identifikaci bankrotních zástupců (44,828 % proti 37,931 %, vztaženo na celkový počet 58 podniků).

Tabulka 8: Klasifikační matice - Altmanovo Z'' - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	22 (37,931 %)	7 (12,069 %)	29 (50 %)	37,931 %	12,069 %
Bankrotní ⁽⁵⁾	3 (5,172 %)	26 (44,828 %)	29 (50 %)	44,828 %	5,172 %
Celkem ⁽⁶⁾	25 (43,103 %)	33 (56,896 %)	58 (100 %)	82,759 %	17,241 %

⁽¹⁾ Confusion matrix - Altman's Z'' - 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

6. 2. 4. Altmanovo Z'' - optimalizace dělicího bodu

Průměrná spolehlivost modelu dosahovala dle původního prahového bodu 85,63 %. Cílem snahy o zvýšení jeho úspěšnosti bylo opět nalezení takové hodnoty dělicího bodu, pro kterou bude součet chybných klasifikací nejmenší. Tímto postupem vyšel jako optimální bod **-0,52**. Výsledky ověření, zda tento bod skutečně přináší zlepšení pravdivosti klasifikace, zachycuje tabulka 9.

Tabulka 9: Optimalizace - Altmanovo Z'' - spolehlivost ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	50,00%	37,93%	87,93%	44,83%	48,28%	93,10%
2	48,28%	37,93%	86,21%	36,21%	44,83%	81,03%
3	44,83%	37,93%	82,76%	25,86%	43,10%	68,97%
Průměr ⁽⁶⁾	47,70%	37,93%	85,63%	35,63%	45,40%	81,03%

⁽¹⁾ Optimization - Altman's Z'' - Accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Original;

⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

Pokus o zvýšení úspěšnosti modelu Z'' aplikací nové hodnoty dělicího bodu přinesl negativní výstup, jelikož došlo k jejímu poklesu o 4,6 procentní body na 81,03 %. Rovněž se změnil poměr správných klasifikací v jednotlivých skupinách, a sice ve prospěch skutečně bankrotních podniků (nárůst z 37,93 % na 45,40 %). Podíl správně zařazených skutečně nebankrotních entit tedy klesl ze 47,70 % na 35,63 %. Přestože se v horizontu predikce jednoho roku před úpadkem podařilo zvýšit úspěšnost na 93,10 %, v období tří let před úpadkem byla spolehlivost pouze 68,97 %.

6. 3. Index IN95

Rozdělením šedé zóny subjektů, u kterých se mohou objevit problémy se splácením závazků na polovinu, byla získána hodnota prahového bodu **1,5**. Za nebankrotní

podniky tento model považuje takové, které mají dobré finanční zdraví a bezproblémově hradí své závazky. Do této skupiny bude případ klasifikován při výsledném skóre nad 1,5. Bankrotní třída odpovídá problémovým entitám s nedostatečnou schopností hradit závazky s pravděpodobnými existenčními problémy. Subjekt je zařazen do této kategorie při hodnotě indexu menší nebo rovné 1,5.

Následuje sestavení klasifikačních matic, ověřující míru příznivých klasifikací v obdobích jednoho a tří let před úpadkem.

6. 3. 1. Index IN95 - jeden rok před úpadkem

Z tabulky 10 je zřejmé, že celková spolehlivost indexu IN95 v tomto období činila 87,931 %, což představuje 51 z 58 podniků. Mylná klasifikace nastala ve zbylých 7 případech, činila tedy 12,069 %.

Tabulka 10: Klasifikační matice - IN95 - 1 rok před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	26 (44,828 %)	3 (5,172 %)	29 (50 %)	44,828 %	5,172 %
Bankrotní ⁽⁵⁾	4 (6,897 %)	25 (43,103 %)	29 (50 %)	43,103 %	6,897 %
Celkem ⁽⁶⁾	30 (51,724 %)	28 (48,276 %)	58 (100 %)	87,931 %	12,069 %

⁽¹⁾ Confusion matrix - IN95 - 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

Při pohledu na skupinu skutečně nebankrotních subjektů jich model pravdivě zařadil 89,655 % (26 z 29). Podíl chybně predikovaných entit je tedy roven 10,345 % (3 z 29). Ze skupiny ve skutečnosti bankrotních podniků bylo dosaženo 86,207% úspěšnosti (25 z 29) a tedy 13,793% chybovosti (3 z 29). Spolehlivost vztažená na celý vzorek 58 subjektů vyšla pro obě skupiny podobně – 44,828 % pro nebankrotní a 43,103 % pro bankrotní část.

6. 3. 2. Index IN95 - dva roky před úpadkem

Při snaze uspíšit včasnost varování na období dvou let před rokem, ve kterém byl prohlášen úpadek, se úspěšnost modelu značně snížila – o 8,621 procentních bodů na 79,310 % (46 z 58). Podíl chybně klasifikovaných entit se zvýšil na 20,690 % (12 z 58). Klasifikační matici zobrazuje tabulka 11.

Tabulka 11: Klasifikační matice - IN95 - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	<i>Nebankrotní</i> ⁽⁴⁾	<i>Bankrotní</i> ⁽⁵⁾			
<i>Nebankrotní</i> ⁽⁴⁾	25 (43,103 %)	4 (6,897 %)	29 (50 %)	43,103 %	6,897 %
<i>Bankrotní</i> ⁽⁵⁾	8 (13,793 %)	21 (36,207 %)	29 (50 %)	36,207 %	13,793 %
Celkem ⁽⁶⁾	33 (56,897 %)	25 (43,103 %)	58 (100 %)	79,310 %	20,690 %

⁽¹⁾ Confusion matrix - IN95 - 2 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

Rovněž ve struktuře predikce v jednotlivých skupinách nastaly mírné změny. Poměr pravdivých zařazení skutečně nebankrotních podniků byl 86,207 % (25 z 29), tzn. 13,793 % mylných (4 z 29). Ze skupiny skutečně bankrotních subjektů jich bylo spolehlivě zařazeno 72,414 % (21 z 29). To se rovná 27,586% chybovosti (8 z 29). Model zde byl celkově spolehlivější v případě nebankrotní skupiny (43,103 % proti 36,207 % bankrotní).

6. 3. 3. Index IN95 - tři roky před úpadkem

Tabulka 12 zobrazuje spolehlivost a chybovost modelu při snaze včasné varovat již tři roky před úpadkem. Oproti předchozímu období spolehlivost klesla o 3,448 procentních bodů na 75,862 % (44 z 58). Mylná predikce proběhla u 24,138 % případů (14 z 58).

Skutečně nebankrotních podniků bylo klasifikováno 79,310 % (23 z 29) zdárně a 20,690 % chybně. U druhé skupiny skutečně bankrotních proběhlo 72,414 % (21 z 29) zařazení pravdivých a 27,586 % (8 z 29) mylných. Vyšší spolehlivost z celkového vzorku opět nastala u nebankrotních entit (39,655 % proti 36,207 % bankrotních).

Tabulka 12: Klasifikační matice - IN95 - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	<i>Nebankrotní</i> ⁽⁴⁾	<i>Bankrotní</i> ⁽⁵⁾			
<i>Nebankrotní</i> ⁽⁴⁾	23 (39,655 %)	6 (10,345 %)	29 (50 %)	39,655 %	10,345 %
<i>Bankrotní</i> ⁽⁵⁾	8 (13,793 %)	21 (36,207 %)	29 (50 %)	36,207 %	13,793 %
Celkem ⁽⁶⁾	31 (53,448 %)	27 (46,552 %)	58 (100 %)	75,862 %	24,138 %

⁽¹⁾ Confusion matrix - IN95 - 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

6. 3. 4. Index IN95 – optimalizace dělicího bodu

Při původním klasifikačním pravidlu s prahovou hranicí 1,5 dosahoval index IN95 průměrné spolehlivosti 81,03 %. Následuje pokus o zlepšení této klasifikační přesnosti. Opět se vychází z hodnoty dělicího bodu, pro který je souhrnný počet mylně klasifikovaných subjektů minimální. Toto kritérium splňuje bod **0,81**. Výsledky ověření hypotézy, že nový bod zvýší predikční úspěšnost, ukazuje tabulka 13:

Aplikace nepřinesla žádoucí efekt, jelikož došlo k poklesu celkové průměrné spolehlivosti o 2,29 procentních bodů na 78,74 %. Vyšší úspěšnost stále vykazuje klasifikace skutečně bankrotních podniků, kde ale došlo k poklesu z 38,51 % na konečných 34,48 %. Naopak ve skupině skutečně nebankrotních subjektů index zaznamenal zvýšení pravdivého zařazení ze 42,53 % na 44,25 %. Se vzdalující se dobou před úpadkem opět dochází ke klesající predikční schopnosti.

Tabulka 13: Optimalizace - IN95 - spolehlivost ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	43,10%	44,83%	87,93%	41,38%	44,83%	86,21%
2	36,21%	43,10%	79,31%	32,76%	46,55%	79,31%
3	36,21%	39,66%	75,86%	29,31%	41,38%	70,69%
Průměr ⁽⁶⁾	38,51%	42,53%	81,03%	34,48%	44,25%	78,74%

⁽¹⁾ Optimization - IN95 - Accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Original;

⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

6. 4. Index IN99

Tento index, soustředící se na tvorbu hodnoty pro vlastníky, je spíše bonitního charakteru, nicméně zde byl zahrnut z důvodu srovnání využitelnosti s ostatními indexy manželů Neumaierových. Rozdělením šedé zóny, poukazující na potenciální problémy na polovinu, došlo k získání dělicího bodu ve výši **1,377**. Klasifikace jako nebankrotní odpovídá hodnotě indexu vyšší než 1,377 a značí tvorbu kladného ekonomického zisku a dobré finanční zdraví. Pokud vyjde index menší nebo roven 1,377, nastává zařazení do bankrotní třídy, odrážející záporný ekonomický zisk.

Rovněž zde dojde k sestavení klasifikačních matic, resp. zhodnocení spolehlivosti modelu v období jednoho až tří let před úpadkem.

6. 4. 1. Index IN99 - jeden rok před úpadkem

Výslednou klasifikační matici zachycuje tabulka 14. V případě predikce jeden rok předem nabývá index IN99 celkové spolehlivosti 68,966 % (40 z 58). Ta odpovídá souhrnné chybovosti ve 31,034 % (18 z 58) případů.

Přesnost zařazení skutečně nebankrotních byla pouhých 41,379 % (12 z 19), což odpovídá mylné klasifikaci 58,621 % (17 z 29) případů. Spolehlivost identifikace skutečně bankrotních entit vyšla podstatně vyšší. Správně bylo těchto podniků predikováno 96,552 % (28 z 29), zatímco chybně pouhých 3,448 % (1 z 29). Index vykazoval z tohoto důvodu vyšší spolehlivost u druhé skupiny. Z celkového vzorku 58 entit jich zdárně zařadil 48,276 % jako bankrotní a jenom 20,690 % jako nebankrotní.

Tabulka 14: Klasifikační matice - IN99 - 1 rok před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	12 (20,690 %)	17 (29,310 %)	29 (50 %)	20,690 %	29,310 %
Bankrotní ⁽⁵⁾	1 (1,724 %)	28 (48,276 %)	29 (50 %)	48,276 %	1,724 %
Celkem ⁽⁶⁾	13 (22,414 %)	45 (77,586 %)	58 (100 %)	68,966 %	31,034 %

⁽¹⁾ Confusion matrix - IN99 - 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

6. 4. 2. Index IN99 - dva roky před úpadkem

Z tabulky 15 je zřejmé, že v celkové spolehlivosti indexu při varování dva roky předem došlo k poklesu o 6,897 procentních bodů na 62,069 % (36 z 58). Podíl mylně zařazených entit tak o stejné procento vrostl na 37,931 % (22 z 58).

K pravdivé klasifikaci skutečně nebankrotních podniků došlo v pouhých 37,931 % (11 z 29) případech, zatímco 62,069 % (18 z 29) případů se zařadilo špatně. Bankrotních subjektů index predikoval 86,207 % (25 z 29) správně a 13,793 % (4 z 29) chybně. Z celého vzorku 58 podniků byla zaznamenána značně vyšší spolehlivost při predikci skutečně bankrotních entit (43,103 % proti 18,966 % nebankrotních).

Tabulka 15: Klasifikační matice - IN99 - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	<i>Nebankrotní</i> ⁽⁴⁾	<i>Bankrotní</i> ⁽⁵⁾			
<i>Nebankrotní</i> ⁽⁴⁾	11 (18,966 %)	18 (31,034 %)	29 (50 %)	18,966 %	31,034 %
<i>Bankrotní</i> ⁽⁵⁾	4 (6,897 %)	25 (43,103 %)	29 (50 %)	43,103 %	6,897 %
Celkem ⁽⁶⁾	15 (25,862 %)	43 (74,138 %)	58 (100 %)	62,069 %	37,931 %

⁽¹⁾ Confusion matrix - IN99 - 2 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

6. 4. 3. Index IN99 - tři roky před úpadkem

Uspíšení včasnosti varování na tři roky dopředu vedlo k výsledné celkové spolehlivosti 63,793 % (37 z 58). Ve srovnání s o rok kratším obdobím nastalo její zvýšení o 1,724 procentních bodů. Celková chybovost tedy proběhla u 36,207 % (21 z 29) klasifikací. Tabulka 16 prezentuje odpovídající klasifikační matici:

Tabulka 16: Klasifikační matice - IN99 - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	<i>Nebankrotní</i> ⁽⁴⁾	<i>Bankrotní</i> ⁽⁵⁾			
<i>Nebankrotní</i> ⁽⁴⁾	12 (20,690 %)	17 (29,310 %)	29 (50 %)	20,690 %	29,310 %
<i>Bankrotní</i> ⁽⁵⁾	4 (6,897 %)	25 (43,103 %)	29 (50,%)	43,103 %	6,897 %
Celkem ⁽⁶⁾	16 (27,586 %)	42 (72,414 %)	58 (100 %)	63,793 %	36,207 %

⁽¹⁾ Confusion matrix - IN99 - 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

Podniky skutečně nebankrotní byly zařazeny s 41,379% úspěšností (12 z 29) a 58,621% chybovostí (17 z 29). Naopak spolehlivost klasifikace skutečně bankrotních entit dosáhla 86,207 % (25 z 29). To odpovídá chybovosti 13,793 % (4 z 29). Relativně k celému vzorku byl model úspěšnější u bankrotních podniků (43,103 % proti 20,690 % u nebankrotních).

6. 4. 4. Index IN99 – optimalizace dělicího bodu

Při původní prahové hodnotě model klasifikoval s pouze 64,94% úspěšností. To tedy odpovídá 35,06% chybovosti. Za účelem zlepšení predikční schopnosti byl hledán takový dělicí bod, který vykazuje nejnižší počet chybně zařazených podniků. Na základě tohoto kritéria vyšel jako optimální bod **0,22**.

Tabulka 17: Optimalizace - IN99 - spolehlivost ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	48,28%	20,69%	68,97%	31,03%	48,28%	79,31%
2	43,10%	18,97%	62,07%	18,97%	48,28%	67,24%
3	43,10%	20,69%	63,79%	13,79%	43,10%	56,90%
Průměr ⁽⁶⁾	44,83%	20,11%	64,94%	21,26%	46,55%	67,82%

⁽¹⁾ Optimization - IN99 - Accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Original;

⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

Tabulka 17 prezentuje výsledky aplikace nové prahové hodnoty. Podařilo se zvýšit celkovou průměrnou spolehlivost tohoto indexu o 2,88 procentních bodů na 67,82 %. Tím se snížil podíl mylně klasifikovaných subjektů o stejnou výši na 32,18 %. Došlo také ke změně ve struktuře pravdivého zařazení podle jednotlivých skupin. Vyšší úspěšnost nyní index vykazuje u skupiny skutečně bankrotních entit (nárůst z 21,11 % na 46,55 %). Naopak ve skutečně nebankrotní skupině nastalo snížení spolehlivosti ze 44,83 % na 21,26 %. Při funkci varování jeden rok před úpadkem došlo ke značnému zvýšení úspěšnosti na 79,31%, avšak tři roky před úpadkem nyní model pravdivě klasifikuje pouze 56,90 % případů.

6. 5. Index IN01

Opětovným rozdělením šedé zóny na polovinu byl získán prahový bod ve výši **1,26**. Subjekt s kladným ekonomickým ziskem je klasifikován jako nebankrotní. K této situaci dojde při výsledné hodnotě indexu vyšší než 1,26. Bankrotní zařazení odpovídá podniku, který směřuje k úpadku a nastane, pokud vyjde skóre indexu menší nebo rovno hodnotě 1,26.

Posouzení spolehlivosti indexu při aplikaci na vybraný vzorek proběhne rovněž v obdobích jeden až tři roky před úpadkem, přičemž výsledky budou opět zaneseny do klasifikačních matic.

6. 5. 1. Index IN01 - jeden rok před úpadkem

Z tabulky 18 lze vidět, že při posouzení schopnosti predikce v tomto časovém úseku má model celkem 77,587% úspěšnost (45 z 58) a 22,413% chybovost (13 z 58).

Tabulka 18: Klasifikační matice - IN01 - 1 rok před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	19 (32,759 %)	10 (17,241 %)	29 (50 %)	32,759 %	17,241 %
Bankrotní ⁽⁵⁾	3 (5,172 %)	26 (44,828 %)	29 (50 %)	44,828 %	5,172 %
Celkem ⁽⁶⁾	22 (37,931 %)	36 (62,069 %)	58 (100 %)	77,587 %	22,413 %

⁽¹⁾ Confusion matrix - IN01 - 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

Ze skupiny skutečně nebankrotních podniků jich bylo 65,517 % (19 z 29) klasifikováno správně a 34,483 % (10 z 29) mylně. Zařazení skutečně bankrotních entit proběhlo s 89,655% spolehlivostí (26 z 29), naopak chybně bylo určeno 10,345 % (3 z 29) entit. Celkově měl tento index vyšší úspěšnost klasifikace bankrotních podniků (44,828 % proti 32,759 % nebankrotních).

6. 5. 2. Index IN01 - dva roky před úpadkem

Výsledky snahy o uspíšení predikce na dva roky vyjadřuje tabulka 19. Zde ve srovnání s předcházejícím kratším časovým horizontem došlo k poklesu celkové spolehlivosti o 6,898 procentních bodů na 70,689 % (41 z 58). O shodnou výši naopak vzrostla celková chybovost, konkrétně na 29,311 % (17 z 58).

Entity skutečně nebankrotní byly klasifikovány s 55,172% přesností (16 z 29), což představovalo zmýlení ve 44,828 % (13 z 29) případech. Spolehlivost zařazení skutečně bankrotních podniků nabyla 86,207 % (25 z 29). To znamená, že chybovost indexu představuje 13,793 % (4 z 29). Vyšší úspěšnost klasifikace model dosahoval v tomto období u skupiny bankrotních subjektů (43,103% všech klasifikací z celkového vzorku, proti 27,586 % skupiny nebankrotních).

Tabulka 19: Klasifikační matice - IN01 - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	16 (27,586 %)	13 (22,414 %)	29 (50 %)	27,586 %	22,414 %
Bankrotní ⁽⁵⁾	4 (6,897 %)	25 (43,103 %)	29 (50 %)	43,103 %	6,897 %
Celkem ⁽⁶⁾	20 (34,483 %)	38 (65,517 %)	58 (100 %)	70,689 %	29,311 %

⁽¹⁾ Confusion matrix - IN01 - 2 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

6. 5. 3. Index IN01- tři roky před úpadkem

Výsledkem ověření spolehlivosti diskriminace tři roky před úpadkem je klasifikační matice prezentovaná tabulkou 20. Ve srovnání s o rok kratším časovým obdobím došlo k opětovnému zvýšení úspěšnosti modelu, a sice o 6,897 procentních bodů na 77,586 % (45 z 58). Poměr chybovosti se potom rovná 22,414 % (13 z 58). Tyto údaje nabývají téměř shodných hodnot jako v období jednoho roku před úpadkem.

Tabulka 20: Klasifikační matice - IN01 - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	18 (31,034 %)	11 (18,966 %)	29 (50 %)	31,034 %	18,966 %
Bankrotní ⁽⁵⁾	2 (3,448 %)	27 (46,552 %)	29 (50 %)	46,552 %	3,448 %
Celkem ⁽⁶⁾	20 (34,483 %)	38 (65,517 %)	58 (100 %)	77,586 %	22,414 %

⁽¹⁾ Confusion matrix - IN01 - 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

Klasifikace skutečně nebankrotních podniků proběhla s 62,069% spolehlivostí (18 z 29), což odpovídá 37,931% mylnému zařazení (11 z 29). U diskriminace skutečně bankrotních entit byla zjištěna 93,103% úspěšnost (27 z 29) a odpovídající 6,897% chybovost (2 z 29). Také relativně k celému vzorku byl model spolehlivější při klasifikaci skutečně bankrotních podniků (46,552 % proti 31,034 % u nebankrotních).

6. 5. 4. Index IN01- optimalizace dělicího bodu

Na základě původního dělicího bodu vykazuje index celkovou průměrnou spolehlivost 75,29%, což se rovná 24,71% chybovosti. To znamená, že téměř každý čtvrtý subjekt je mylně klasifikován. Prostřednictvím optimalizace prahové hodnoty je proveden pokus o zlepšení těchto nežádoucích výsledků. Přitom se vychází z dělicího bodu, pro který je celkový počet chybně zařazených subjektů minimální. Danému kritériu odpovídá bod **0,65**.

Výsledky při původním i novém dělicím bodu zachycuje tabulka 21. Došlo k žádoucímu zvýšení celkové průměrné spolehlivosti o 6,32 procentních bodů na hodnotu 81,61 %. Podíl mylně zařazených entit se tak snížil na 18,39 %. V rámci dílčích skupin mají nyní vyšší úspěšnost skutečně bankrotní podniky (zvýšení z 30,46 % na 44,25 %). Skutečně nebankrotní entity jsou nyní klasifikovány s 37,36% spolehlivostí.

Tabulka 21: Optimalizace - IN01 - spolehlivost ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	44,83%	32,76%	77,59%	44,83%	44,83%	89,66%
2	43,10%	27,59%	70,69%	36,21%	46,55%	82,76%
3	46,55%	31,03%	77,59%	31,03%	41,38%	72,41%
Průměr ⁽⁶⁾	44,83%	30,46%	75,29%	37,36%	44,25%	81,61%

⁽¹⁾ Optimization - IN01 - Accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Original;

⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

6. 6. Index IN05

Klasifikační pravidlo, odvíjející se od dělicího bodu **1,25**, vzniklo rozdělením šedé zóny na polovinu. Nebankrotními podniky jsou takové, které jsou úspěšné a tvoří kladný ekonomický zisk. Do této skupiny bude entita zařazena při výsledném skóre vyšším než 1,25. Naopak u podniků směřujících k úpadku dochází ke klasifikaci do bankrotní skupiny, a to při hodnotě indexu menší nebo rovné 1,25. K ověření spolehlivosti dojde znovu ve v období jednoho až tří let před úpadkem.

6. 6. 1. Index IN05 - jeden rok před úpadkem

V tomto období index klasifikuje vybraný vzorek se spolehlivostí 77,587 % (45 z 58). Celková chybovost je tedy rovna 22,413 % (13 z 58). Úspěšnost je tedy shodná s indexem IN01 v daném období.

Tabulka 22: Klasifikační matice - IN05 - 1 rok před úpadkem ⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	19 (32,759 %)	10 (17,241 %)	29 (50 %)	32,759 %	17,241 %
Bankrotní ⁽⁵⁾	3 (5,172 %)	26 (44,828 %)	29 (50 %)	44,828 %	5,172 %
Celkem ⁽⁶⁾	22 (37,931 %)	36 (62,069 %)	58 (100 %)	77,587 %	22,413 %

⁽¹⁾ Confusion matrix - IN05 - 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;

Zdroj: vzorek podniků, vlastní zpracování

Za totožnou lze označit i strukturu spolehlivosti klasifikací v dílčích skupinách. Skutečně nebankrotní entity byly zařazeny s 65,517% přesností (19 z 29). To odpovídá mylnému zařazení v 34,483 % (10 z 29) případů. Diskriminace skutečně bankrotních subjektů dosáhla 89,655% spolehlivosti (26 z 29), což představuje chybovost ve výši

10,345 procentních bodů (3 z 29). Úspěšnost klasifikace vztažená k celému vzorku byla vyšší u bankrotní skupiny (44,828 % proti 32,759 % nebankrotní).

6. 6. 2. Index IN05 - dva roky před úpadkem

Tabulka 23 ukazuje, že výsledky ověření klasifikační spolehlivosti jsou v tomto případě opět naprosto stejné jako výsledky indexu IN01 v totéž období. Pro komentář tedy viz kapitola 6. 5. 2. Index IN01 - dva roky před úpadkem.

Tabulka 23: Klasifikační matice - IN05 - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	16 (27,586 %)	13 (22,414 %)	29 (50 %)	27,586 %	22,414 %
Bankrotní ⁽⁵⁾	4 (6,897 %)	25 (43,103 %)	29 (50 %)	43,103 %	6,897 %
Celkem ⁽⁶⁾	20 (34,483 %)	38 (65,517 %)	58 (100 %)	70,689 %	29,311 %

⁽¹⁾ Confusion matrix - IN05 - 2 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

6. 6. 3. Index IN05- tři roky před úpadkem

Jak lze vidět z tabulky 24, rovněž za toto období poskytuje index IN05 výsledky spolehlivosti shodné s indexem IN01 za období tři roky před úpadkem. Bližší komentář lze tedy najít v kapitole 6. 5. 3. Index IN01- tři roky před úpadkem.

Tabulka 24: Klasifikační matice - IN05 - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	18 (31,034 %)	11 (18,966 %)	29 (50 %)	31,034 %	18,966 %
Bankrotní ⁽⁵⁾	2 (3,448 %)	27 (46,552 %)	29 (50 %)	46,552 %	3,448 %
Celkem ⁽⁶⁾	20 (34,483 %)	38 (65,517 %)	58 (100 %)	77,586 %	22,414 %

⁽¹⁾ Confusion matrix - IN05 - 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification;
Zdroj: vzorek podniků, vlastní zpracování

6. 6. 4. Index IN05- optimalizace dělicího bodu

Index IN05 vykazuje při původní hodnotě dělicího bodu celkovou průměrnou spolehlivost ve výši 75,29 %, což se rovná celkové průměrné chybovosti 24,71 %. Pokus o zlepšení těchto hodnot byl proveden způsobem nalezení takového bodu, který minimalizuje počet mylně zařazených entit. Dle tohoto kritéria došlo k výběru bodu 0,65. Jak lze zjistit s tabulky 25, původní výsledky i výsledky s novým dělicím bodem

jsou naprosto totožné s indexem IN01 (viz kapitola 6. 5. 4. Index IN01- optimalizace dělicího bodu).

Tabulka 25: Optimalizace - IN05 - spolehlivost ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	44,83%	32,76%	77,59%	44,83%	44,83%	89,66%
2	43,10%	27,59%	70,69%	36,21%	46,55%	82,76%
3	46,55%	31,03%	77,59%	31,03%	41,38%	72,41%
Průměr ⁽⁶⁾	44,83%	30,46%	75,29%	37,36%	44,25%	81,61%

⁽¹⁾ Optimization - IN05 - Accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Original;

⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

6. 7. Tafflerův základní model

V tomto případě nebyla úprava klasifikačního pravidla nutná. Nebankrotní klasifikace při výsledném skóre větším než nula značí malou pravděpodobnost úpadku. Klasifikace do bankrotní skupiny naopak nastane při výsledku menším než nula a odpovídá velké pravděpodobnosti úpadku. Spolehlivost bude ověřována taktéž za období jednoho až tří let před úpadkem.

6. 7. 1. Taffler - základní - jeden rok před úpadkem

Tabulka 26 zobrazuje klasifikační matici, která obsahuje výsledky ověření spolehlivosti Tafflerova základního modelu za období jednoho roku před úpadkem. Zařazení proběhlo s celkovou úspěšností 67,242 % (39 z 58). To odpovídá celkové chybovosti v 32,758 % (19 z 58) případů.

Tabulka 26: Klasifikační matice - Tafflerův základní model - 1 rok před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	28 (48,276 %)	1 (1,724 %)	29 (50 %)	48,276 %	1,724 %
Bankrotní ⁽⁵⁾	18 (31,034 %)	11 (18,966 %)	29 (50 %)	18,966 %	31,034 %
Celkem ⁽⁶⁾	46 (79,310 %)	12 (20,690 %)	58 (100 %)	67,242 %	32,758 %

⁽¹⁾ Confusion matrix - Taffler's basic model- 1 year before bankruptcy; ⁽²⁾ Real group;

⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

Klasifikace skutečně nebankrotních podniků nastala s 96,552% úspěšností (28 z 29). Mylné zařazení se tedy uskutečnilo u 3,448 % (1 z 29) takových subjektů. Správně

diskriminovaných skutečně bankrotních entit bylo 62,069 % (18 z 29), což odpovídá chybovosti 37,931 % (11 z 29). Relativně k celému vzorku podniků byl model podstatně úspěšnější u nebankrotní skupiny (48,276 % proti 18,966 % bankrotní).

6. 7. 2. Taffler - základní – dva roky před úpadkem

Výsledky posouzení schopnosti včasné varovat již dva roky před úpadkem zachycuje tabulka 27. V tomto období model vykázal 62,069% celkovou spolehlivost (36 z 58). To představovalo pokles o 5,173 procentních bodů oproti předchozímu kratšímu období. Lze snadno odvodit, že chybovost nastala v 37,931 % (22 z 58) situací.

Ve skutečnosti nebankrotní podniky byly klasifikovány s úspěšností 96,552 % (28 z 29). Podíl mylně zařazených entit se tedy rovnal 3,448 % (1 z 29). Skutečně bankrotních subjektů se zařadilo 27,586 % (8 z 29) pravdivě a 72,414 % (21 z 29) chybně. Značně vyšší spolehlivosti nabývá model u nebankrotní skupiny (48,276 % proti 13,793 % bankrotní).

Tabulka 27: Klasifikační matice - Tafflerův základní model - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	28 (48,276 %)	1 (1,724 %)	29 (50 %)	48,276 %	1,724 %
Bankrotní ⁽⁵⁾	21 (36,207 %)	8 (13,793 %)	29 (50 %)	13,793 %	36,207 %
Celkem ⁽⁶⁾	49 (84,483 %)	9 (15,517 %)	58 (100 %)	62,069 %	37,931 %

⁽¹⁾ Confusion matrix - Taffler's basic model- 2 years before bankruptcy; ⁽²⁾ Real group;

⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

6. 7. 3. Taffler - základní – tři roky před úpadkem

Tabulka 28 prezentuje spolehlivost a chybovost při uspíšení varování na období tři let před úpadkem. Správné zařazení celkem proběhlo v 56,897 % (33 z 58) případů. Spolehlivost tedy oproti předchozímu kratšímu časovému horizontu klesla o 5,172 procentních bodů. Mylná klasifikace se tedy uskutečnila u 43,103 % (25 z 58) všech podniků.

V souvislosti se skupinou skutečně nebankrotních podniků jich Tafflerův základní model v tomto období zařadil 89,655% (26 z 29). Chybně predikované entity představuje podíl 10,345 % (3 z 29). Ze skupiny skutečně bankrotních subjektů bylo spolehlivě identifikováno 75,862 % (22 z 29). Tomu odpovídá 24,138% mylná

klasifikace (7 z 29). Úspěšnost klasifikace vztažená na celý vzorek 58 podniků vyšla patrně vyšší u nebankrotní skupiny (44,828 % proti 12,069 % bankrotní).

Tabulka 28: Klasifikační matice - Tafflerův základní model - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	26 (44,828 %)	3 (5,172 %)	29 (50 %)	44,828 %	5,172 %
Bankrotní ⁽⁵⁾	22 (37,931 %)	7 (12,069 %)	29 (50 %)	12,069 %	37,931 %
Celkem ⁽⁶⁾	48 (82,759 %)	10 (17,241 %)	58 (100 %)	56,897 %	43,103 %

⁽¹⁾ Confusion matrix - Taffler's basic model- 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

6. 7. 4. Taffler - základní – optimalizace dělicího bodu

Z předchozích výsledků lze shrnout, že celková průměrná úspěšnost tohoto modelu vychází ve výši 62,07 % (chybovost 37,93 %). Reakcí na tuto značně nízkou predikční spolehlivost je pokus o nalezení vhodnějšího dělicího bodu, který by ji zvýšil. Za prahovou hodnotu byla zvolena taková, která se pojí s nejnižším počtem mylně klasifikovaných podniků. Té odpovídá bod **0,22**.

Tabulka 29: Optimalizace -Taffler základní model - spolehlivost ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	18,97%	48,28%	67,24%	44,83%	39,66%	84,48%
2	13,79%	48,28%	62,07%	39,66%	36,21%	75,86%
3	12,07%	44,83%	56,90%	41,38%	36,21%	77,59%
Průměr ⁽⁶⁾	14,94%	47,13%	62,07%	41,95%	37,36%	79,31%

⁽¹⁾ Optimization - Taffler's basic model - Accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Original; ⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

Tabulka 29 shrnuje výsledky ověření spolehlivosti pro původní i nový dělicí bod. Dochází ke značnému zvýšení úspěšnosti, a sice o 17,24 procentních bodů na 79,31 %, což odpovídá snížení chybovosti na 20,69 %. K výraznému zlepšení dochází v každém ze tří časových horizontů predikce úpadku. Vyšší podíl pravdivě klasifikovaných entit nyní vychází u skutečně nebankrotní skupiny (zvýšení z 14,94 % na 41,95 %). V případě skutečně bankrotní skupiny nastal pokles ze 47,13 % na 37,36 %.

6. 8. Tafflerův modifikovaný model

Taktéž u tohoto modelu byla šedá zóna rozdělena na polovinu a vznikl tak dělicí bod 0,25. Při výsledném skóre vyšším než 0,25 dochází k zařazení do nebankrotní skupiny, které odpovídá malé pravděpodobnosti úpadku. Případná velká pravděpodobnost úpadku se odrazí v klasifikaci do bankrotní třídy a nastane tomu tak při hodnotě modelu menší nebo rovné 0,25. V nejbližší části práce potom dochází k ověření spolehlivosti za časové horizonty jednoho až tří let před úpadkem

6. 8. 1. Taffler - modifikovaný - jeden rok před úpadkem

Z tabulky 30 lze zjistit, že celková spolehlivost zde vychází ve výši 62,069 % (36 z 58). Mylná klasifikace tudíž proběhla v 37,931 % (22 z 58) případech. Ve srovnání se základním modelem v tomto období dochází k poklesu úspěšnosti o 5,173 procentních bodů.

Tabulka 30: Klasifikační matice - Tafflerův modifikovaný model - 1 rok před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	28 (48,276 %)	1 (1,724 %)	29 (50 %)	48,276 %	1,724 %
Bankrotní ⁽⁵⁾	21 (36,207 %)	8 (13,793 %)	29 (50 %)	13,793 %	36,207 %
Celkem ⁽⁶⁾	49 (84,483 %)	9 (15,517 %)	58 (100 %)	62,069 %	37,931 %

⁽¹⁾ Confusion matrix - Taffler's modified model- 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

V situaci posouzení predikce skutečně nebankrotních subjektů byla vykázána 96,552% spolehlivost (28 z 29). Chybovost tedy činila 3,448 % (1 z 29). Pravdivé zařazení skutečně bankrotních entit nastalo v pouhých 27,586 % (8 z 29) případů, což představuje 72,414% mylnou klasifikaci (21 z 29). Celkově byl model spolehlivější při predikci ze skutečně nebankrotní skupiny (48,276 % proti 13,793 % bankrotní).

6. 8. 2. Taffler - modifikovaný – dva roky před úpadkem

Klasifikační matici při varování dva roky předem zobrazuje tabulka 31. Vůči předchozímu kratšímu období došlo k poklesu klasifikační spolehlivosti o 5,172 procentních bodů na 56,897 % (33 z 58). Chybovost tedy byla 43,103% (25 z 58). Při srovnání se základním Tafflerovým indexem v tomtéž období poklesla úspěšnost rovněž o 5,172 procentních bodů.

Spolehlivost zařazení skutečně nebankrotních entit vyšla 96,552 % (28 z 29). Ta se rovná 3,448% chybě (1 z 29). Diskriminace skutečně bankrotních podniků proběhla s 17,241% úspěšností (5 z 29). Z toho lze dopočítat 82,759% mylnou klasifikaci (24 z 29). Relativně k celému vzorku byl model značně spolehlivější u nebankrotní skupiny (zařazeno 48,276 % proti 8,621 % bankrotní).

Tabulka 31: Klasifikační matice - Tafflerův modifikovaný model - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	28 (48,276 %)	1 (1,724 %)	29 (50 %)	48,276%	1,724%
Bankrotní ⁽⁵⁾	24 (41,379 %)	5 (8,621 %)	29 (50 %)	8,621%	41,379%
Celkem ⁽⁶⁾	52 (89,655 %)	6 (10,345 %)	58 (100 %)	56,897%	43,103%

⁽¹⁾ Confusion matrix - Taffler's modified model- 2 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

6. 8. 3. Taffler - modifikovaný – tři roky před úpadkem

Výsledky obsahuje tabulka 32. Ve srovnání s kratším dvouletým obdobím model vykazuje totožnou celkovou spolehlivost, a to 56,897 % (33 z 58). Celková chybovost je tedy 43,103 % (25 z 58). Tyto hodnoty se rovněž shodují se základním modelem.

Tabulka 32: Klasifikační matice - Tafflerův modifikovaný model - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	27 (46,552 %)	2 (3,448 %)	29 (50 %)	46,552 %	3,448 %
Bankrotní ⁽⁵⁾	23 (39,655 %)	6 (10,345 %)	29 (50 %)	10,345 %	39,655 %
Celkem ⁽⁶⁾	50 (86,207 %)	8 (13,793 %)	58 (100 %)	56,897 %	43,103 %

⁽¹⁾ Confusion matrix - Taffler's modified model- 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

Struktura dílčích skupin však byla odlišná. Skutečně nebankrotních subjektů se predikovalo 93,103 % (27 z 29) správně a 6,897 % (2 z 29) mylně. V případě podniků, které byly ve skutečnosti bankrotní, došlo k 79,310% spolehlivosti (23 z 29) a 20,690% chybovosti (6 z 29). Vzhledem k celkovému počtu 58 entit nastala vyšší pravdivá klasifikace u nebankrotní skupiny (46,552 % proti 10,345 % bankrotní).

6. 8. 4. Taffler - modifikovaný – optimalizace dělicího bodu

Průměrná celková spolehlivost modelu dosahovala dle původního prahového bodu pouhých 58,62 %, což představuje 41,38% chybovost. Cílem snahy o zvýšení jeho

úspěšnosti bylo opět nalezení takového dělicího bodu, pro který bude součet chybných klasifikací nejmenší. Na základě této metody vyšel jako optimální bod **0,48**. Výsledky ověření, zda nový bod přináší zlepšení klasifikace, zachycuje tabulka 33:

Tabulka 33: Optimalizace - Taffler modifikovaný model - spolehlivost ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	13,79%	48,28%	62,07%	29,31%	46,55%	75,86%
2	8,62%	48,28%	56,90%	27,59%	41,38%	68,97%
3	10,34%	46,55%	56,90%	25,86%	43,10%	68,97%
Průměr ⁽⁶⁾	10,92%	47,70%	58,62%	27,59%	43,68%	71,26%

⁽¹⁾ Optimization - Taffler's modified model - Accuracy; ⁽²⁾ Years before bankruptcy;

⁽³⁾ Original; ⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

Aplikace nového prahového bodu přinesla žádoucí výsledek, neboť došlo ke zlepšení úspěšnosti o 12,64 procentních bodů na 71,26 %. Celková průměrná mylná klasifikace se tak snížila na 28,74 %. Vůči původnímu pravidlu se nezměnil fakt, že model je úspěšnější při identifikaci skutečně bankrotních podniků (úspěšnost zde však poklesla ze 47,70 % na 43,68 %). Skutečně nebankrotní subjekty byly zařazovány s 10,92% úspěšností, která se nyní zvýšila na 27,59 %. Rovněž nastalo zlepšení spolehlivosti ve všech časových obdobích z hlediska včasnosti predikce.

6. 9. Gurčíkův index

Rozdělením původní šedé zóny, vyhrazené pro průměrné podniky, byl získán dělicí bod ve výši **0,6**. Nebankrotní klasifikace, ke které dojde při výsledku indexu vyšším než 0,6, odpovídá prosperujícím podnikům. Pokud vyjde hodnota indexu menší nebo rovna 0,6, subjekt se zařadí do bankrotní třídy odrážející neprosperující podniky. Spolehlivost bude ověřována taktéž za období jednoho až tří let před úpadkem.

6. 9. 1. Gurčíkův index – jeden rok před úpadkem

Klasifikační matice je prezentována tabulkou 34. V časovém horizontu jednoho roku předem varuje index s celkovou spolehlivostí 84,483 % (49 z 58). Souhrnná chybovost tudíž byla 15,517 % (9 z 58).

Tabulka 34: Klasifikační matice - Gurčíkův index - 1 rok před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	20 (34,483 %)	9 (15,517 %)	29 (50 %)	34,483 %	15,517 %
Bankrotní ⁽⁵⁾	0 (0,000 %)	29 (50,000 %)	29 (50 %)	50,000 %	0,000 %
Celkem ⁽⁶⁾	20 (34,483 %)	38 (65,517 %)	58 (100 %)	84,483 %	15,517 %

⁽¹⁾ Confusion matrix - Gurčík's index- 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

Při klasifikaci skutečně nebankrotních subjektů spolehlivost vyšla ve výši 68,966 % (20 z 29), což představovalo 31,034% chybovost (9 z 29). Podniky skutečně bankrotní byly ve všech případech zařazeny pravdivě. Mylné zařazení tedy v této skupině neproběhlo. Vyšší úspěšnost (relativně k celému vzorku) index vykazoval u bankrotní skupiny (50,000 % proti 34,483 % nebankrotní).

6. 9. 2. Gurčíkův index – dva roky před úpadkem

Ve srovnání s předchozím kratším obdobím přineslo posouzení celkové spolehlivosti predikce již dva roky před úpadkem pokles o 5,172 procentních bodů na 79,311 % (46 z 58). Celková chybovost se zvýšila o totéž procento na 20,689 % (12 z 58). Výsledky zobrazuje tabulka 35:

Tabulka 35: Klasifikační matice - Gurčíkův index - 2 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	Nebankrotní ⁽⁴⁾	Bankrotní ⁽⁵⁾			
Nebankrotní ⁽⁴⁾	19 (32,759 %)	10 (17,241 %)	29 (50 %)	32,759 %	17,241 %
Bankrotní ⁽⁵⁾	2 (3,448 %)	27 (46,552 %)	29 (50 %)	46,552 %	3,448 %
Celkem ⁽⁶⁾	21 (36,207 %)	37 (63,793 %)	58 (100 %)	79,311 %	20,689 %

⁽¹⁾ Confusion matrix - Gurčík's index- 2 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

Rovněž došlo k mírné změně v jednotlivých skupinách. Diskriminace skutečně nebankrotních podniků nastala s 65,517% úspěšností (19 z 29). Pravdivé zařazení se tak nepodařilo u 34,483 % (10 z 29) takových subjektů. Spolehlivě diskriminovaných skutečně bankrotních entit vyšlo 93,103 % (27 z 29) a představuje 6,897% mylné určení (2 z 29). Úspěšnost zařazení, vztažená k celému vzorku, byla vyšší u bankrotních entit (46,552 % proti 32,759 % nebankrotních).

6. 9. 3. Gurčický index – tři roky před úpadkem

Tabulka 36 představuje klasifikační matici při posouzení schopnosti varování tři roky před úpadkem. Vůči předchozímu kratšímu horizontu nenastala žádná změna, tudíž celková spolehlivost a chybovost zůstává na stejných hodnotách. Rovněž podíl úspěšnosti a mylného zařazení v jednotlivých skupinách se nikterak neliší. Pro podrobnější komentář tedy viz kapitola 6. 9. 2. Gurčický index – dva roky před úpadkem.

Tabulka 36: Klasifikační matice - Gurčický index - 3 roky před úpadkem⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Celkem ⁽⁶⁾	Spolehlivost ⁽⁷⁾	Chybovost ⁽⁸⁾
	<i>Nebankrotní</i> ⁽⁴⁾	<i>Bankrotní</i> ⁽⁵⁾			
<i>Nebankrotní</i> ⁽⁴⁾	19 (32,759 %)	10 (17,241 %)	29 (50 %)	32,759 %	17,241 %
<i>Bankrotní</i> ⁽⁵⁾	2 (3,448 %)	27 (46,552 %)	29 (50 %)	46,552 %	3,448 %
Celkem ⁽⁶⁾	21 (36,207 %)	37 (63,793 %)	58 (100 %)	79,311 %	20,689 %

⁽¹⁾ Confusion matrix - Gurčický's index- 3 years before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Total; ⁽⁷⁾ Accuracy; ⁽⁸⁾ Rate of misclassification; Zdroj: vzorek podniků, vlastní zpracování

6. 9. 4. Gurčický index – optimalizace dělicího bodu

Při použití původní prahové hodnoty dosahoval model průměrné celkové spolehlivosti 81,03 %, což odpovídá chybovosti ve výši 18,97 % všech případů. Následný pokus si za cíl klade zlepšení těchto hodnot. Dochází ke hledání takového bodu, kterému odpovídá minimální hodnota chybně klasifikovaných subjektů. Tímto bodem je hodnota **-0,65**. Tabulka 37 obsahuje výstupy testování, zda nové klasifikační pravidlo přinese odpovídající zvýšení spolehlivosti modelu.

Pokus přinesl evidentně negativní výsledek. Průměrná celková spolehlivost poklesla o 1,72 procentních bodů na 79,31%. O stejnou hodnotu vzrostla průměrná celková chybovost, a sice na 20,69 %. Dále se změnila struktura pravdivých zařazení v jednotlivých skupinách. Spolehlivější klasifikace proběhla nyní u ve skutečnosti bankrotních podniků (zvýšení z 33,33 % na 45,98 %). Skupina skutečně nebankrotních subjektů zaznamenala pokles v počtu správně zařazených entit, a sice ze 47,70 % na 33,33 %.

Tabulka 37: Optimalizace - Gurčikův index - spolehlivost ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Původní ⁽³⁾			Optimalizace ⁽⁴⁾		
	True negatives	True positives	Celkem ⁽⁵⁾	True negatives	True positives	Celkem ⁽⁵⁾
1	50,00%	34,48%	84,48%	43,10%	48,28%	91,38%
2	46,55%	32,76%	79,31%	32,76%	46,55%	79,31%
3	46,55%	32,76%	79,31%	24,14%	43,10%	67,24%
Průměr ⁽⁶⁾	47,70%	33,33%	81,03%	33,33%	45,98%	79,31%

⁽¹⁾ Optimization - Altman's Z' - Accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Original;

⁽⁴⁾ Optimization; ⁽⁵⁾ Total; ⁽⁶⁾ Average; Zdroj: vzorek podniků, vlastní zpracování


6. 10. Shrnutí výsledků ověření modelů a optimalizace

V předchozích kapitolách došlo k ověření klasifikační spolehlivosti devíti predikčních modelů. Zkoumání úspěšnosti zařazení proběhlo ve třech časových horizontech včasnosti varování.

Nejvyšší přesnosti v průměru dosáhl Altmanův model Z''. A to i přesto, že se vzorek testovaných podniků liší z hlediska teritoriálního i časového od toho, na kterém byl model vytvořen. Více než 80% úspěšnost měly také index IN95 a Gurčikův index. Nejnižší úspěšnost naopak zaznamenaly oba Tafflerovy modely, vytvořené primárně k analýze britských podniků. Velmi nízkou predikční spolehlivost vykázal rovněž index IN99, který je však určen k posuzování bonity ve smyslu dosahování ekonomického zisku nežli k predikci úpadku.

Graf 2 ilustruje dosažená procenta spolehlivosti jednotlivých modelů v obdobích jednoho až tří let před úpadkem, jakož i jejich průměrnou hodnotu. Na vodorovné ose jsou dílčí modely, svislá osa zobrazuje vykázanou spolehlivost v procentech.

Graf 2: Spolehlivost stávajících modelů ⁽¹⁾



⁽¹⁾ Accuracy of existing models; Horizontal axis = Model; Vertical axis = Accuracy; ⁽²⁾ 1 year before bankruptcy; ⁽³⁾ 2 years before bankruptcy; ⁽⁴⁾ 3 years before bankruptcy; ⁽⁵⁾ Total Average; Zdroj: vzorek podniků, vlastní zpracování

V reakci na poměrně nízké vypočítané klasifikační přesnosti jednotlivých modelů došlo k provedení pokusů o jejich zlepšení nalezením vhodnějšího dělicího bodu. Za optimální prahovou hodnotu byla považována taková, která odpovídala nejmenšímu počtu mylně zařazených subjektů (minimalizující celkovou chybovost). Tabulka 38 prezentuje dělicí body jednotlivých modelů i výsledné spolehlivosti modelů při původních i nových dělicích bodech.

V návaznosti na výsledky lze shrnout, že zvýšení spolehlivosti se podařilo provést pouze u těch modelů, které vykazují nižší původní hodnoty. Úspěšnější klasifikace tak nastala u indexů IN99, IN01, IN05 a u obou Tafflerových modelů. Altmanovo Z' zůstalo na shodných hodnotách. Nové dělicí body přinesly naproti tomu negativní změnu u modelů, diskriminujících s vyšší původní spolehlivostí. K poklesu celkového počtu pravdivých zařazení tak nastalo u Altmanova Z'', indexu IN95 a Gurčikova indexu. Tyto modely již tedy nelze zlepšit, alespoň v rámci zvoleného algoritmu.

Tabulka 38: Vyhodnocení optimalizace - dělicí body a spolehlivost⁽¹⁾

Model	Původní ⁽²⁾		Optimalizace ⁽³⁾		Rozdíl spolehlivosti ⁽⁶⁾
	<i>Dělicí bod</i> ⁽⁴⁾	<i>Spolehlivost</i> ⁽⁵⁾	<i>Dělicí bod</i> ⁽⁴⁾	<i>Spolehlivost</i> ⁽⁵⁾	
Altmanovo Z' ⁽⁷⁾	2,065	79,31%	1,7	79,31%	0,00%
Altmanovo Z'' ⁽⁸⁾	1,85	85,63%	-0,52	81,03%	-4,60%
IN95 ⁽⁹⁾	1,5	81,03%	0,81	78,74%	-2,30%
IN99 ⁽¹⁰⁾	1,377	64,94%	0,22	67,82%	2,87%
IN01 ⁽¹¹⁾	1,26	75,29%	0,65	81,61%	6,32%
IN05 ⁽¹²⁾	1,25	75,29%	0,65	81,61%	6,32%
Taffler zákl. ⁽¹³⁾	0	62,07%	0,22	79,31%	17,24%
Taffler modif. ⁽¹⁴⁾	0,25	58,62%	0,48	71,26%	12,64%
Gurčíkův index ⁽¹⁵⁾	0,6	81,03%	-0,65	79,31%	-1,72%

⁽¹⁾ Optimization assessment - thresholds and accuracy; ⁽²⁾ Original; ⁽³⁾ Optimization;

⁽⁴⁾ Threshold; ⁽⁵⁾ Accuracy; ⁽⁶⁾ Accuracy difference; ⁽⁷⁾ Altman's Z'; ⁽⁸⁾ Altman's Z''; ⁽⁹⁾ Index IN95;

⁽¹⁰⁾ Index IN99; ⁽¹¹⁾ Index IN01; ⁽¹²⁾ Index IN05; ⁽¹³⁾ Taffler's basic; ⁽¹⁴⁾ Taffler's modified;

⁽¹⁵⁾ Gurčík's index; Zdroj: vlastní zpracování

7. Profilová analýza

Kapitola zahrnuje jednorozměrnou analýzu vybraných poměrových ukazatelů. Za cíl si klade posoudit, zda tyto dílčí nezávislé proměnné zvládnou diskriminovat daný vzorek podniků do příslušné binární závislé proměnné. Za tímto účelem dojde k využití grafického zobrazení i statistického aparátu (testy shody středních hodnot).

Celkový počet zkoumaných ukazatelů se rovná 28 a jejich výčet, včetně značení a vzorců pro výpočet, byl proveden v metodice v kapitole 5. 4. Výběr poměrových ukazatelů.


7. 1. Grafická profilová analýza

Jako podstatu lze označit posouzení vývoje průměrných hodnot zvolených ukazatelů, a to zvláště pro obě skupiny subjektů za období tří let před úpadkem. Základní hypotéza tvrdí, že daný ukazatel má schopnost klasifikovat do zvolené skupiny v případě, když existuje významný rozdíl ve vývoji jeho průměrných hodnot. Čím blíže k období úpadku se podnik nachází, tím by měly dané ukazatele vykazovat větší rozdíl jejich hodnot u jednotlivých skupin (bankrotních a nebankrotních subjektů).

Z ukazatelů rentability se nejlépe jeví VHÚD/A, VHD/A, VHD/V, DLR, VHD/KCK a VHML/A. Z grafů těchto ukazatelů lze usoudit, že se zkracující se dobou do úpadku vykazují rozdílný vývoj hodnot. Naopak ukazatele VH/VK a RDZ nabývají jeden rok před úpadkem podobných hodnot.

Graf 3 zobrazuje vývoj ukazatele VHD/A za období tří let před úpadkem. Zelená křivka spojuje průměrné hodnoty ukazatele jednotlivých období pro nebankrotní subjekty. Totéž zobrazuje červená křivka pro bankrotní subjekty. U jednotlivých bodů křivek jsou rovněž zobrazeny chybové úsečky, odpovídající 95% intervalu spolehlivosti (konfidenčnímu intervalu). Kratší úsečky představují nižší variabilitu daného bodu (průměru), resp. jeho vyšší spolehlivost. Z grafu lze vidět, že již v časovém horizontu tří let před úpadkem dosahují bankrotní podniky horší průměrné hodnoty. Důležitější je však evidentní fakt, že u bankrotních podniků dochází k poklesu průměrných hodnot daného ukazatele s přibližujícím se úpadkem. Rozdíl podtrhují neklesající hodnoty nebankrotních subjektů.

Graf 3: Vývoj VHD/A bankrotních a nebankrotních podniků⁽¹⁾




⁽¹⁾ Development of VHD/A ratio of bankruptcy and prospering enterprises; Horizontal axis = Years efore bankruptcy; Vertical axis = VHD/A ratio;

⁽²⁾ Prospering enterprises; ⁽³⁾ Bankruptcy enterprises; Zdroj: vzorek podniků, vlastní zpracování

Ve skupině ukazatelů účinnosti a vázanosti dochází k méně zřetelným rozdílům. Ukazatel V/A nabývá v období tří a jednoho roku před úpadkem podobných hodnot. O schopnosti diskriminovat lze na první pohled uvažovat u zbývajících ukazatelů KZ/V, Z/V a OA/V. Ty vykazují rozdílné hodnoty v časovém horizontu jednoho roku před úpadkem. Příčinou je ohromný propad hodnoty celkových výnosů v daném období jednoho z bankrotních podniků. Tato odlehlá hodnota tak způsobila vychýlení průměrné hodnoty, což však činí závěr o možnosti diskriminace chybným.

Příkladem může být vázanost krátkodobých závazků KZ/V, kterou znázorňuje graf 4. V jednoletém horizontu dochází k vychýlení průměrné hodnoty ukazatele vlivem obrovského poklesu celkových výnosů jednoho subjektu z analyzovaného vzorku.

Graf 4: Vývoj KZ/V bankrotních a nebankrotních podniků⁽¹⁾




⁽¹⁾ Development of KZ/V ratio of bankruptcy and prospering enterprises; Horizontal axis = Years efore bankruptcy; Vertical axis = KZ/V ratio; ⁽²⁾ Prospering enterprises; ⁽³⁾ Bankruptcy enterprises; Zdroj: vzorek podniků, vlastní zpracování

V početné skupině ukazatelů finanční stability se při grafickém posouzení diskriminace osvědčilo více zástupců. Ukazatele CK/A, KCK/A, ČPK/A či VK/A vykazují viditelné zhoršení již v období dvou let před úpadkem, přičemž jeden rok předem nastane další nezanedbatelné zhoršení. V případě podílu čistého pracovního kapitálu na výnosech ČPK/V se rozdíl v hodnotách projevuje jeden rok před úpadkem. Ukazatele L3, L2, L1, OA/CK nebo VHÚD/NÚ se buď mírně zhoršují, nebo vykazují stabilně nízké nežádoucí hodnoty.

Graf 5 zachycuje vývoj ukazatele podílu čistého pracovního kapitálu ČPK/A za časový horizont tří let před úpadkem. Vývoj hodnot nebankrotních entit je evidentně stabilní. Ukazatel naproti tomu vykazuje již tři roky před úpadkem horší průměrnou hodnotu. S dalším zkracováním časového horizontu před úpadkem dochází k nepříjemnému poklesu průměrů vykazovaných hodnot.

Graf 5: Vývoj ČPK/A bankrotních a nebankrotních podniků⁽¹⁾




⁽¹⁾ Development of Net Working Capital / Total Assets ratio of bankruptcy and prospering enterprises; Horizontal axis = Years before bankruptcy; Vertical axis = Net Working Capital / Total Assets ratio; ⁽²⁾ Prospering enterprises; ⁽³⁾ Bankruptcy enterprises; Zdroj: vzorek podniků, vlastní zpracování

Skupina ukazatelů nákladovosti obsahuje pouze dva zástupce. Nákladovost výkonové spotřeby VS/V poskytuje možnost predikce úpadku v horizontu jednoho roku předem, jelikož k významnějším rozdílům hodnot dochází právě v tomto období. Mzdová nákladovost OsN/V vykazuje zhoršující se tendenci u bankrotních podniků již dva roky předem.

To lze vidět v grafu 6. Hodnoty ukazatele u nebankrotních podniků mírně klesají. V případě bankrotních subjektů však dochází k jejich růstu. Za období tří let před úpadkem hodnoty bankrotních entit jejich budoucímu úpadku nenapovídají, dokonce jsou oproti nebankrotním v průměru lepší. Dva roky předem však dochází k převýšení hodnot nebankrotních subjektů bankrotními a jeden rok předem je nárůst ještě zřetelnější.

Graf 6: Vývoj OsN/V bankrotních a nebankrotních podniků⁽¹⁾




⁽¹⁾ Development of OsN/V ratio of bankruptcy and prospering enterprises; Horizontal axis = Years efore bankruptcy; Vertical axis = OsN/V ratio; ⁽²⁾ Prospering enterprises; ⁽³⁾ Bankruptcy enterprises; Zdroj: vzorek podniků, vlastní zpracování

Dále došlo k analýze čtyř ukazatelů založených na cash flow. Na možnost diskriminace poukazují zejména ukazatele CF/A, CF/CK a CF/KZ, u nichž dochází ke zhoršení již dva roky před úpadkem či k setrvání na podobně nízkých hodnotách po dobu všech tří období. Ukazatel CF/V vykazuje významnější rozdíl až jeden rok předem.

Graf 7 zobrazuje vývoj průměrných hodnot rentability aktiv z cash flow bankrotních a nebankrotních podniků. Výsledky bankrotní skupiny vycházejí již tři roky před úpadkem horší, nicméně se zkracujícím se časovým horizontem do úpadku nastává každoročně znatelný propad.

Graf 7: Vývoj CF/A bankrotních a nebankrotních podniků⁽¹⁾



⁽¹⁾ Development of CF/A ratio of bankruptcy and prospering enterprises; Horizontal axis = Years efore bankruptcy; Vertical axis = CF/A ratio;⁽²⁾ Prospering enterprises;
⁽³⁾ Bankruptcy enterprises; Zdroj: vzorek podniků, vlastní zpracování

7. 2. Testování shody středních hodnot ukazatelů

Za účelem správné klasifikace dílčích subjektů do příslušné skupiny dochází k předpokladu, že se skupinové hustoty pravděpodobnosti uvažovaného znaku překrývají co nejméně. Prostřednictvím jednorozměrného t-testu o shodě středních hodnot dvou nezávislých vzorků tak bude ověřeno, zda se liší průměrné hodnoty daného ukazatele nebankrotních a bankrotních podniků. Nulová hypotéza tvrdí, že střední hodnoty obou skupin jsou shodné. Alternativní hypotéza vyjadřuje opak, tedy že lze dané střední hodnoty považovat za rozdílné. K zamítnutí nulové hypotézy ve prospěch alternativní dochází v situaci, kdy výsledná hodnota p (tzv. p-value) je nižší než zvolená hladina významnosti $\alpha = 0,05$.

Homogenita (shoda) rozptylů daných dvou skupin je důležitým předpokladem, jehož platnost se odráží ve výběru správného t-testu. Pro jeho ověření zde byl využit robustní Levenův test, který analyzuje absolutní odchylky hodnot skupinových průměrů. Pokud test prokáže statistickou významnost, tedy když výsledné p-value je nižší než zde zvolená hladina významnosti $\alpha = 0,05$, lze zamítnout nulovou hypotézu a rozptyly považovat za rozdílné. V tomto případě se provádí t-test s oddělenými odhady rozptylů, tzv. Welchův t-test.

Tabulka 39 zobrazuje výsledky testů středních hodnot dílčích poměrových ukazatelů. Za každý z uvažovaných časových horizontů před úpadkem jsou uvedeny střední hodnoty ukazatele za skupinu nebankrotních (μ (NB)) a bankrotních (μ (B)) subjektů, jakož i příslušná p-value.

Tabulka 39: Průměrné hodnoty a p-value vybraných ukazatelů ⁽¹⁾

Ukazatel ⁽²⁾	1 rok před úpadkem ⁽³⁾			2 roky před úpadkem ⁽⁴⁾			3 roky před úpadkem ⁽⁵⁾		
	μ (NB)	μ (B)	p-value	μ (NB)	μ (B)	p-value	μ (NB)	μ (B)	p-value
DLR	0,3914	-0,9409	0,0000	0,3544	-0,5716	0,0001	0,3400	-0,2049	0,0000
VHD/A	0,0774	-0,3192	0,0000	0,0665	-0,2643	0,0029	0,0482	-0,1089	0,0015
VHML/A	0,3198	-0,6454	0,0002	0,2869	-0,3319	0,0002	0,2912	-0,1159	0,0001
VHD/KCK	0,4495	-0,2511	0,0001	0,3070	-0,2010	0,0000	0,2778	-0,1694	0,0007
VHÚD/A	0,0821	-0,3002	0,0000	0,0716	-0,2494	0,0037	0,0535	-0,0952	0,0023
RDZ	0,6803	0,7267	0,9379	0,0983	-0,2358	0,4688	0,2933	0,0765	0,2678
VH/VK	0,6415	0,5358	0,8525	0,1136	0,6365	0,5912	0,2472	-0,2961	0,1679
VHD/V	0,0522	-0,7894	0,0939	0,0422	-0,2147	0,0108	0,0311	-0,1683	0,0288
V/A	2,2427	2,0560	0,7016	1,8891	2,1354	0,5569	2,1520	2,0370	0,7986
KZ/V	0,1731	7,4401	0,2578	0,2016	0,7462	0,0045	0,1898	0,7225	0,0206
OA/V	0,4133	2,6716	0,3024	0,4441	0,4393	0,9460	0,3791	0,6179	0,0772
Z/V	0,0926	0,7464	0,2789	0,1243	0,1885	0,1688	0,0940	0,2011	0,0271
L3	2,9633	0,5655	0,0000	3,0936	0,7288	0,0004	2,6437	0,9968	0,0009
L2	2,3503	0,3320	0,0002	2,4920	0,4181	0,0015	2,0982	0,6472	0,0033
L1	0,9733	0,0525	0,0011	0,9145	0,0272	0,0063	0,7497	0,0637	0,0068
CK/A	0,4638	1,5785	0,0000	0,5007	1,2667	0,0003	0,5013	0,9446	0,0000
VK/A	0,5212	-0,6013	0,0000	0,4917	-0,2804	0,0003	0,4822	0,0383	0,0000
KCK/A	0,3828	1,3062	0,0001	0,4103	1,0315	0,0007	0,4103	0,7854	0,0002
OA/CK	2,6280	0,4765	0,0001	2,6446	0,6175	0,0009	2,3422	0,7496	0,0009
ČPK/A	0,3050	-0,7397	0,0000	0,2994	-0,4371	0,0002	0,2748	-0,1617	0,0002
ČPK/V	0,2059	-6,0064	0,2169	0,2026	-0,5668	0,0114	0,1635	-0,5473	0,0636
VHÚD/NÚ	118,4641	-6,4271	0,2228	68,0174	-19,1861	0,0938	25,6264	-6,8211	0,0474
OsN/V	0,2403	0,3617	0,1227	0,2446	0,2668	0,6741	0,2622	0,2070	0,2449
VS/V	0,5425	0,9905	0,2782	0,5473	0,6337	0,3349	0,5401	0,6499	0,2077
CF/A	0,1023	-0,2734	0,0000	0,0951	-0,2196	0,0035	0,0794	-0,0744	0,0007
CF/CK	0,4511	-0,1655	0,0000	0,3848	-0,0839	0,0000	0,3473	-0,0607	0,0001
CF/KZ	0,6337	-0,2388	0,0000	0,5233	-0,1719	0,0000	0,4556	-0,1695	0,0001
CF/V	0,0738	-0,7290	0,0964	0,0701	-0,1784	0,0064	0,0612	-0,1335	0,0121

⁽¹⁾ Mean values and p-values of analysed ratios ; ⁽²⁾ Ratio; ⁽³⁾ 1 year before bankruptcy; ⁽⁴⁾ 2 years before bankruptcy; ⁽⁵⁾ 3 years before bankruptcy; Zdroj: vzorek podniků, vlastní zpracování

Červené zvýraznění náleží p-hodnotám těch ukazatelů, vykazujícím v daném období statistickou významnost. Jeden rok před úpadkem vyšlo 16 ukazatelů jako statisticky signifikantní, tedy došlo k prokázání rozdílných středních hodnot. Významná odlišnost mezi středními hodnotami nastala u 20 ukazatelů v období dvou let před úpadkem,

avšak pouze 16 z nich ji nadále vykazovalo i ve zmíněném jednoletém horizontu. Za statisticky signifikantní označil test v období tří let před úpadkem 21 ukazatelů, přičemž opět pouze u 16 z nich došlo k pokračujícím významně rozdílným hodnotám i ve dvou zbývajících obdobích do úpadku.

7. 3. Vyhodnocení výsledků profilové analýzy

Dle výsledků grafického provedení profilové analýzy lze tvrdit, že z ukazatelů rentability je pro predikci nejvhodnější míra zisku VHD/A. Daný fakt potvrzují výstupy statistických testů, které tuto proměnnou rovněž označily za nejvýznamnější ze všech 28 analyzovaných. Z této skupiny jsou dále neméně vhodné ukazatele DLR, VHML/A, VHD/KCK či VHÚD/A, které jsou rovněž statisticky vysoce významné, což potvrzuje také grafické zobrazení. Ukazatele účinnosti a vázanosti neposkytly graficky přesvědčivé výsledky o dostačující schopnosti klasifikace, což bylo stvrzeno i testy shody středních hodnot, jelikož žádný z ukazatelů v této skupině nebyl statisticky významný.

Dle grafického posouzení ukazatelů finanční stability se jako predikce schopné jeví ukazatele CK/A, L3, L2, L1, VK/A, KCK/A, OA/CK, ČPK/A a VHÚD/NÚ. Statistické testy označily, kromě VHÚD/NÚ, tytéž proměnné za významné, tudíž způsobilé diskriminace do správné třídy. Nejlepší výsledek z hlediska statistické signifikance má celková zadluženost CK/A. Oba analyzované ukazatele nákladovosti určil test shody středních hodnot statisticky nevýznamnými, čili neprokazujícími signifikantní rozdíly v jejich průměrných hodnotách. Taktéž grafické posouzení spěje ke shodným závěrům, jelikož například nákladovost výkonové spotřeby VS/V vykazuje rozdíl pouze v období jednoho roku před úpadkem.

Z ukazatelů založených na cash flow vyšly graficky nejlépe CF/A, CF/CK a CF/KZ. Rovněž statistické testy poskytly stvrzení, že tyto proměnné vykazují vysoce významné rozdíly ve středních hodnotách a jsou tudíž vhodné k predikci úpadku. Přitom rentabilita aktiv z cash flow CF/A se ukázala být nejvýznamnější.

Samotný autor profilové analýzy William Beaver však připustil, že model obsahující více proměnných by měl přinést lepší predikční spolehlivost, tudíž následující kapitoly budou věnovány tvorbě vícerozměrného modelu.

8. Tvorba vícerozměrného modelu diskriminační analýzou

Cílem této kapitoly je vytvořit prostřednictvím diskriminační analýzy vícerozměrný model, který dokáže s dostatečnou spolehlivostí diskriminovat mezi zvolenou binární proměnnou (bankrotní a nebankrotní subjekty). Nejprve dojde k ověření jednoho z teoretických předpokladů, kdy bude testována normalita zvolených ukazatelů. Poté proběhne tvorba několika modelů s využitím dopředné krokové diskriminační analýzy, stavějící model krok za krokem. Následuje ověření klasifikační spolehlivosti vytvořených modelů metodou resubstituce. Rovněž proběhne snaha o zvýšení těchto primárních spolehlivostí přehodnocením prahových hodnot pro zařazení do jednotlivých skupin. V závěru se vybere finální model, vykazující nejvyšší průměrnou klasifikační úspěšnost.

8. 1. Testy normality

Za účelem ověření nulové hypotézy o shodě empirického rozdělení s teoretickým normálním rozdělením byl využit Kolmogorovův-Smirnovův test. V případě, že hodnota odpovídajícího p-value vyjde nižší než zvolená hladina významnosti $\alpha = 0,05$, dochází k zamítnutí nulové hypotézy ve prospěch alternativní, tvrdící nerovnost těchto rozdělení.

Tabulka 40 zachycuje výsledky testů normality vybraných 28 ukazatelů, konkrétně hodnoty p-value pro nebankrotní (NB p-value) a bankrotní (B p-value) podniky během jednoho až tří let před úpadkem. Červeně vyznačené hodnoty značí zamítnutí hypotézy, že se empirické a teoretické normální rozdělení rovnají. Nastalo tomu tak alespoň v jednom období téměř ve všech případech, kromě ukazatelů V/A a OsN/V.

Tabulka 40: Kolmogorov-Smirnovovy testy ⁽¹⁾

Ukazatel ⁽²⁾	1 rok před úpadkem ⁽³⁾		2 roky před úpadkem ⁽⁴⁾		3 roky před úpadkem ⁽⁵⁾	
	NB p-value	B p-value	NB p-value	B p-value	NB p-value	B p-value
DLR	> 0,2	> 0,2	> 0,2	< 0,05	> 0,2	< 0,1
VHD/A	< 0,1	> 0,2	> 0,2	< 0,01	> 0,2	< 0,05
VHML/A	> 0,2	< 0,1	> 0,2	< 0,1	> 0,2	< 0,05
VHD/KCK	< 0,01	> 0,2	< 0,01	< 0,15	< 0,15	< 0,01
VHÚD/A	< 0,1	> 0,2	> 0,2	< 0,01	< 0,2	< 0,01
RDZ	< 0,01	< 0,05	< 0,05	< 0,01	< 0,01	< 0,05
VH/VK	< 0,01	< 0,15	< 0,15	< 0,01	< 0,05	< 0,01

Ukazatel ⁽²⁾	1 rok před úpadkem ⁽³⁾		2 roky před úpadkem ⁽⁴⁾		3 roky před úpadkem ⁽⁵⁾	
	NB p-value	B p-value	NB p-value	B p-value	NB p-value	B p-value
VHD/V	< 0,15	< 0,01	> 0,2	< 0,01	> 0,2	< 0,01
V/A	< 0,15	< 0,15	> 0,2	< 0,1	> 0,2	< 0,15
KZ/V	< 0,05	< 0,01	< 0,15	< 0,01	> 0,2	< 0,01
OA/V	< 0,2	< 0,01	> 0,2	> 0,2	> 0,2	< 0,1
Z/V	> 0,2	< 0,01	> 0,2	< 0,1	< 0,1	< 0,1
L3	< 0,05	> 0,2	< 0,05	> 0,2	< 0,05	< 0,05
L2	< 0,05	> 0,2	< 0,01	> 0,2	< 0,01	< 0,05
L1	< 0,01	< 0,05	< 0,01	< 0,05	< 0,01	< 0,05
CK/A	> 0,2	< 0,1	> 0,2	< 0,05	> 0,2	< 0,01
VK/A	> 0,2	< 0,1	> 0,2	< 0,05	> 0,2	< 0,05
KCK/A	> 0,2	< 0,05	> 0,2	< 0,05	> 0,2	< 0,1
OA/CK	< 0,05	> 0,2	< 0,05	> 0,2	< 0,05	> 0,2
ČPK/A	> 0,2	< 0,1	> 0,2	< 0,05	> 0,2	< 0,1
ČPK/V	> 0,2	< 0,01	> 0,2	< 0,01	> 0,2	< 0,01
VHÚD/NÚ	< 0,01	< 0,01	< 0,01	< 0,01	< 0,01	< 0,01
OsN/V	> 0,2	< 0,1	< 0,15	> 0,2	> 0,2	< 0,15
VS/V	> 0,2	< 0,01	> 0,2	< 0,1	> 0,2	> 0,2
CF/A	< 0,1	> 0,2	> 0,2	< 0,01	< 0,1	< 0,01
CF/CK	< 0,01	> 0,2	< 0,01	> 0,2	< 0,15	< 0,05
CF/KZ	< 0,01	< 0,15	< 0,05	< 0,15	> 0,2	< 0,01
CF/V	< 0,15	< 0,01	> 0,2	< 0,01	> 0,2	< 0,01

⁽¹⁾ Kolmogorov-Smirnovov's tests ; ⁽²⁾ Ratio; ⁽³⁾ 1 year before bankruptcy; ⁽⁴⁾ 2 years before bankruptcy; ⁽⁵⁾ 3 years before bankruptcy; Zdroj: vzorek podniků, vlastní zpracování

8. 2. Tvorba modelu

Prvotní úvahou bylo vytvoření klasifikačního modelu za použití všech 28 vybraných ukazatelů (spojitá nezávisle proměnná). Podle dopředné krokové diskriminační analýzy a defaultních hodnot hladiny významnosti $p = 0,05$ pro zahrnutí i vyjmutí proměnné z modelu, došlo ve čtvrtém kroku k výběru ukazatelů VHD/A, L3 a VHÚD/A. S tímto výsledkem se však nelze spokojit, jelikož proměnné VHD/A a VHÚD/A si jsou obsahově velmi podobné a patrně zde existuje vysoká vzájemná korelace. Tuto nežádoucí skutečnost potvrzují i výsledná protisměrná znaménka koeficientů těchto ukazatelů ve výsledném modelu ($-61,82 \cdot \text{VHÚD/A}$ a $+ 67,47 \cdot \text{VHD/A}$), ačkoli by měla být obě znaménka logicky kladná.

Z tohoto důvodu byly ověřeny míry korelace (vzájemný lineární vztah) mezi všemi zkoumanými ukazateli výpočtem korelačních koeficientů. Na jejich základě došlo

k odstranění vzájemně vysoce korelovaných proměnných s koeficientem v absolutní hodnotě vyšším než 0,8. Tabulka 41 zobrazuje korelační matici výsledných vybraných ukazatelů. Zbývajících ukazatelů tedy jsou: VHD/A, VH/VK, V/A, CK/A, L3, VHÚD/NÚ, OsN/V, CF/KZ a CF/V.

Tabulka 41: Korelační matice vybraných ukazatelů⁽¹⁾

	VHD/A	VH/VK	CK/A	V/A	L3	VHÚD/NÚ	OsN/V	CF/V	CF/KZ
VHD/A	1,00	-0,07	0,07	-0,61	0,44	0,25	-0,20	0,71	0,11
VH/VK	-0,07	1,00	0,32	0,04	-0,09	-0,03	0,04	-0,03	0,05
CK/A	0,07	0,32	1,00	-0,01	-0,12	0,02	-0,19	-0,08	0,19
V/A	-0,61	0,04	-0,01	1,00	-0,48	-0,17	0,18	-0,44	-0,20
L3	0,44	-0,09	-0,12	-0,48	1,00	0,22	0,02	0,65	0,15
VHÚD/NÚ	0,25	-0,03	0,02	-0,17	0,22	1,00	-0,17	0,33	0,10
OsN/V	-0,20	0,04	-0,19	0,18	0,02	-0,17	1,00	-0,20	-0,74
CF/V	0,71	-0,03	-0,08	-0,44	0,65	0,33	-0,20	1,00	0,15
CF/KZ	0,11	0,05	0,19	-0,20	0,15	0,10	-0,74	0,15	1,00

⁽¹⁾ Correlation matrix of the selected ratios; Zdroj: vzorek podniků, vlastní zpracování

S těmito 9 nezávislými proměnnými byla znovu provedena dopředná kroková diskriminační analýza, nejprve se základními přednastavenými hodnotami hladin významnosti $p = 0,05$ pro zahrnutí i vyjmutí. Proces se zastavil ve třetím kroku a zvolil dva ukazatele: VHD/A a L3.

Tabulka 42: Faktorové strukturní koeficienty LDF1⁽¹⁾

Ukazatel ⁽²⁾	Koeficient ⁽³⁾
VHD/A	0,8127
VH/VK	-0,1546
V/A	-0,0750
CK/A	-0,4327
L3	0,6905
VHÚD/NÚ	0,2333
OsN/V	0,0337
CF/V	0,6703
CF/KZ	-0,0039

⁽¹⁾ Factor structure coefficients of LDF1; ⁽²⁾ Ratio;

⁽³⁾ Coefficients; Zdroj: vlastní zpracování

Tzv. faktorové strukturní koeficienty (uvedené v tabulce 42), udávající jednoduché korelace mezi danou funkcí a proměnnými, v následující tabulce potvrzují, že vybrané ukazatele (zejména míra zisku VHD/A) skutečně přispívají ke klasifikaci nejlépe.

Výsledná rovnice modelu LDF1 má následující podobu:

$$LDF_1 = -0,4428 + 5,6137 * \frac{VHD}{A} + 0,6355 * L3$$

Funkční předpis lze upravit do tvaru, využívajícího absolutní člen (konstantu) jako dělicí bod klasifikace. Klasifikačním pravidlo potom zní následovně: Pokud vyjde výsledné skóre modelu menší nebo rovno **0,4428**, subjekt spadá do kategorie úpadkových (bankrotních) podniků. Subjekt bude klasifikován jako neúpadkový (nebankrotní) při výsledném skóre větší než **0,4428**. Zápis využívající konstantu jako dělicí bod:

$$5,6137 * \frac{VHD}{A} + 0,6355 * L3 \leq 0,4428$$

Celková spolehlivost modelu v časovém horizontu jednoho roku před úpadkem vyšla 87,931 %. Jednoduchou klasifikační matici v tomto období zobrazuje tabulka 43:

Tabulka 43: Klasifikační matice - LDF1 - 1 rok před úpadkem ⁽¹⁾

Skutečná třída ⁽²⁾	Klasifikace dle modelu ⁽³⁾		Spolehlivost ⁽⁶⁾
	<i>Nebankrotní</i> ⁽⁴⁾	<i>Bankrotní</i> ⁽⁵⁾	
<i>Nebankrotní</i> ⁽⁴⁾	26 (44,828 %)	3 (5,172 %)	44,828%
<i>Bankrotní</i> ⁽⁵⁾	4 (6,897 %)	25 (43,103 %)	43,103%
Celkem ⁽⁷⁾	30 (51,724 %)	28 (48,276 %)	87,931%

⁽¹⁾Confusion matrix - LDF1- 1 year before bankruptcy; ⁽²⁾ Real group; ⁽³⁾ Classification by model; ⁽⁴⁾ Prosperity; ⁽⁵⁾ Bankruptcy; ⁽⁶⁾ Accuracy; ⁽⁷⁾ Total; Zdroj: vzorek podniků, vlastní zpracování

Další postup ověřuje, zda lze vytvořit spolehlivější model úpravou hladiny významnosti p pro zahrnutí a vyjmutí proměnných z modelu. Postupné zvyšování této hladiny o 0,05 přineslo změnu ve výsledcích až při zvýšení na hodnotu p = 0,15 pro zahrnutí i vyjmutí. Nový model obsahuje tyto 3 ukazatele: VHD/A, CK/A a L3.

Tvar výsledné rovnice je následovný:

$$LDF_2 = 0,3527 + 4,6802 * \frac{VHD}{A} - 0,7719 * \frac{CK}{A} + 0,5675 * L3$$

Podle výše strukturních koeficientů lze jednoznačně stanovit, že největší relativní váhu (významnost) má v i tomto modelu ukazatel rentability - míra zisku VHD/A. Rovnici lze opět přepsat do tvaru, který využívá absolutní člen jako dělicí bod pro

klasifikaci. Pokud vyjde hodnota rovnice menší nebo rovna **-0,3527**, podnik bude zařazen jako úpadkový (bankrotní). Při výsledném skóre větším než **-0,3527** lze subjekt klasifikovat jako neúpadkový (nebankrotní). Zápis modelu potom vypadá následovně:

$$4,6802 * \frac{VHD}{A} - 0,7719 * \frac{CK}{A} + 0,5675 * L3 \leq -0,3527$$

Celková spolehlivost modelu se zvýšením hladiny významnosti a přidáním jedné nezávisle proměnné do modelu zvýšila, a to na 89,655 %.

Při dalším zvýšení hladiny významnosti, tentokrát na $p = 0,3$, byl dopřednou krokovou analýzou získán model o 4 ukazatelích. První čtyři jsou shodné s předchozím modelem – VHD/A, CK/A a L3. K nim přibyl nově ukazatel OsN/V. Celková spolehlivost však zůstala na neměnné úrovni 89,655 %.

Relativně nejvýznamnějším ukazatelem modelu zůstala dle výše strukturního koeficientu míra zisku VHD/A. Nově přidaný ukazatel mzdová nákladovost OsN/V se stává druhou relativně nejvlivnější proměnou funkce. Výsledná rovnice vypadá následovně:

$$LDF_3 = 0,6465 + 4,5370 * \frac{VHD}{A} - 0,7178 * \frac{CK}{A} + 0,6190 * L3 - 1,5189 * \frac{OsN}{V}$$

Absolutní člen lze opět využít jako prahovou hodnotu pro klasifikaci do příslušné alternativní třídy. V případě, že výsledné skóre vyjde menší nebo rovno **-0,6465**, je subjekt zařazen jako úpadkový (bankrotní). Naopak při výsledku vyšším než **-0,6465** dochází ke klasifikaci do skupiny neúpadkových (nebankrotních) podniků. Zápis, ve kterém se konstanta považuje za dělicí bod:

$$4,5370 * \frac{VHD}{A} - 0,7178 * \frac{CK}{A} + 0,6190 * L3 - 1,5189 * \frac{OsN}{V} \leq -0,6465$$

Dodatečným zvýšením hladiny významnosti již ke změně celkové spolehlivosti došlo. Při $p = 0,35$ rovněž nastala další změna ukazatelů, obsažených v modelu. V tomto případě byly v šestém kroku zahrnuty proměnné: VHD/A, VH/VK, CK/A, L3 a OsN/V. Největší relativní význam (váha) je v tomto modelu stále přikládána proměnné míra zisku VHD/A.

Lineární diskriminační funkce má v tomto případě následující tvar:

$$\text{LDF}_4 = 0,5334 + 4,6832 * \frac{\text{VHD}}{\text{A}} + 0,1774 * \frac{\text{VH}}{\text{VK}} - 0,7133 * \frac{\text{CK}}{\text{A}} + 0,6445 * \text{L3} \\ - 1,5962 * \frac{\text{OsN}}{\text{V}}$$

Úspěšnost predikce v jednom roce před úpadkem dosáhla 91,38 %. Rovněž zde lze tuto rovnici upravit do tvaru, používajícího absolutní člen jako dělicí bod pro klasifikaci. Vyjde-li výsledná hodnota skóre menší nebo rovna **-0,5334**, je podnik zařazen do skupiny úpadkových (bankrotních). Naopak skóre **-0,5334** a vyšší odpovídá klasifikaci do neúpadkové (nebankrotní) třídy. Tento tvar vypadá následovně:

$$4,6832 * \frac{\text{VHD}}{\text{A}} + 0,1774 * \frac{\text{VH}}{\text{VK}} - 0,7133 * \frac{\text{CK}}{\text{A}} + 0,6445 * \text{L3} - 1,5962 * \frac{\text{OsN}}{\text{V}} \leq -0,5334$$

8. 3. Ověření spolehlivosti vytvořených modelů

V předchozí kapitole byly vytvořeny 4 varianty lineárních diskriminačních funkcí. Za nejdůležitější vlastnost predikčního modelu lze považovat spolehlivost, se kterou klasifikuje jednotlivé subjekty do příslušné skupiny. Proto nyní dojde k ověření spolehlivosti jednotlivých modelů, a to za tři časové horizonty před úpadkem. Tato metoda vyhodnocení kvality se nazývá resubstituce a vychází ze zpětné aplikace modelu pro zařazení těch jednotek, na základě kterých byl vytvořen.


V grafu 8 jsou zobrazeny dosažené hodnoty spolehlivosti jednotlivých vytvořených modelů za dílčí období jednoho až tří let před úpadkem, stejně jako jejich průměrné hodnoty

Model LDF1 vykazuje hodnotu průměrné spolehlivosti 77,01 %. V období jednoho roku před úpadkem dosahuje nepatrně nižší úspěšnost klasifikace (87,93 %) oproti zbývajícím modelům, což je vynahrazeno v období dvou let před úpadkem, kdy zařazuje s 77,59% spolehlivostí. S tříletým předstihem dokázal model správně klasifikovat 65,52 % případů.

Průměrná spolehlivost modelu LDF2 vyšla ve výši 76,44 %. Oproti prvnímu modelu byl však úspěšnější při klasifikaci v období jednoho roku před úpadkem, kdy vykázal 89,66% spolehlivost. Dále pravdivě zařadil 75,86 % subjektů s dvouletým předstihem a 63,79 % subjektů v horizontu tří let před úpadkem.

Model LDF3 klasifikoval vybrané subjekty s 75,86% průměrnou úspěšností. V období jednoho roku před úpadkem dosáhl shodné spolehlivosti jako model LDF2, tedy 89,66 %. Dva roky předem správně zařadil 75,86 % podniků, s tříletím předstihem tak činil u 62,07 % případů.

Graf 8: Spolehlivost vytvořených diskriminačních funkcí ⁽¹⁾



⁽¹⁾ Accuracy of created diskriminant functions; Horizontal axis = Model; Vertical axis = Accuracy; ⁽²⁾ 1 year before bankruptcy; ⁽³⁾ 2 years before bankruptcy; ⁽⁴⁾ 3 years before bankruptcy; ⁽⁵⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

Posledním vytvořeným modelem byl LDF4, u kterého ověření přineslo průměrnou spolehlivost 77,01 %. To znamená shodnou s prvním modelem. Podíl pravdivě klasifikovaných subjektů byl v období jednoho roku před úpadkem ze všech modelů nejvyšší, a to 91,38 %. Avšak s prodloužením časového horizontu na dva roky již klesl na 74,14 %. V období tří let před úpadkem vykázal spolehlivost ve výši 66,52 %.

8. 4. Optimalizace dělicího bodu vytvořených modelů

Vytvořené modely však nepřinášejí uspokojivé výsledky průměrné spolehlivosti, jejichž výše byla popsána v předchozí kapitole. V reakci na tuto skutečnost následuje pokus o nalezení vhodnějších dělicích bodů, které by zvýšily úspěšnost vytvořených modelů. Postup volby optimální prahové hodnoty je shodný s kapitolou, věnovanou

ověření stávajících modelů. Výsledný bod tak odpovídá takovému, na základě kterého dochází k minimalizaci počtu mylně klasifikovaných subjektů daným modelem.

Tabulka 44: Optimalizace vytvořených modelů - dělicí body a spolehlivost ⁽¹⁾

Model	Původní ⁽²⁾		Optimalizace ⁽³⁾		Rozdíl ⁽⁶⁾
	Dělicí bod ⁽⁴⁾	Spolehlivost ⁽⁵⁾	Dělicí bod ⁽⁴⁾	Spolehlivost ⁽⁵⁾	
LDF1	0,4428	77,01%	0,8916	86,21%	9,20%
LDF2	-0,3527	76,44%	0,1562	85,06%	8,62%
LDF3	-0,6465	75,86%	-0,3161	78,16%	2,30%
LDF4	-0,5334	77,01%	-0,3108	77,59%	0,57%

⁽¹⁾ Optimization of created models - thresholds and accuracy; ⁽²⁾ Original; ⁽³⁾ Optimization;

⁽⁴⁾ Threshold; ⁽⁵⁾ Accuracy; ⁽⁶⁾ Accuracy difference; Zdroj: vzorek podniků, vlastní zpracování

Tabulka 44 zobrazuje původní i nové dělicí body dílčích modelů, včetně výsledných hodnot průměrných spolehlivostí za tři období před úpadkem (v %). Z uvedených výsledků je patrné, že u všech 4 vytvořených modelů došlo k úspěšnému zvýšení predikční spolehlivosti. Taktéž lze poznamenat, že daná spolehlivost se zlepšila či zůstala shodná v každém časovém horizontu. Nová prahová hodnota nejvíce vylepšila model LDF1, který zaznamenal 9,20% nárůst úspěšnosti. U prvních dvou modelů optimalizace přinesla změnu ve struktuře pravdivých zařazení v jednotlivých skupinách, přičemž nyní jsou tyto modely spolehlivější při klasifikaci skutečně bankrotních subjektů

8. 5. Výběr finálního modelu

Na základě původních hodnot dělicích bodů vykazují LDF1 a LDF4 shodně nejvyšší spolehlivost (77,01 %) v průměru za období tří let před úpadkem. Po aplikaci nových hodnot dělicích bodů vykázal největší průměrnou spolehlivost model LDF1, a sice 86,21 %. Tento model byl vytvořený dopřednou krokovou diskriminační analýzou při základní hladině významnosti $p = 0,05$, a to jak pro zahrnutí, tak pro vyjmutí analyzované proměnné z modelu.

V období jednoho roku před úpadkem správně klasifikoval 93,10 % případů. S prodlužujícím se časovým horizontem před úpadkem došlo k očekávanému poklesu počtu pravdivě zařazených subjektů. Model spolehlivě určil 84,48 % případů v období dvou let před úpadkem a 81,03% případů v tříletém předstihu.

Výsledná rovnice modelu vytvořeného diskriminační analýzou tak má tuto podobu:

$$\text{LDF} = 5,6137 * \frac{\text{VHD}}{\text{A}} + 0,6355 * \text{L3} - 0,8916$$

Model obsahuje ukazatele míra zisku VHD/A a běžná likvidita L3. Výsledek klasifikace je tak závislý na dosaženém výsledku hospodaření před zdaněním, celkové velikosti aktiv, velikosti oběžných aktiv a krátkodobých závazků.

Klasifikační pravidlo vychází z optimalizované hodnoty dělícího bodu. Pokud vyjde výsledné skóre rovnice menší nebo rovno **0,8916**, dochází ke klasifikaci do skupiny úpadkových podniků. V případě výsledku vyššího než **0,8916** dochází k zařazení do skupiny neúpadkových subjektů.

9. Tvorba vícerozměrného modelu logistickou regresí

Cílem této kapitoly je vytvořit pomocí logistické regrese model, který dokáže co nejpřesněji klasifikovat vybrané subjekty do jedné z alternativních tříd. Stejně jako u diskriminační analýzy, i zde se bude vycházet z hodnot poměrových ukazatelů pro vybraný vzorek podniků za období jednoho roku před úpadkem, jelikož v tomto časovém horizontu se projevují největší rozdíly mezi hodnotami ukazatelů úpadkových (bankrotních) a neúpadkových (nebankrotních) subjektů. Jako modelovaná pravděpodobnost se zde uvažuje situace, kdy u daného podniku nedojde k úpadku.

9. 1. Tvorba modelu

Taktéž při tvorbě modelu logistickou regresí nejdřív došlo k zúžení původního počtu 28 poměrových ukazatelů na výsledných 9 odebráním těch, které mezi sebou vykázaly vysokou míru korelace. Následně byla provedena dopředná kroková analýza, která postupně krok po kroku zhodnotí všechny nezávisle proměnné a do modelu zahrne tu, která nejvíce přispívá k diskriminaci. Tento proces se následně opakuje. S ponecháním základních hodnot $p = 0,05$ pro zahrnutí i vyjmutí proměnné z modelu došlo v sedmém kroku k zahrnutí těchto dvou ukazatelů: L3 a CF/KZ.

Tabulka 45: Výstup logistické regrese při $p = 0,05$ ⁽¹⁾

Ukazatel ⁽²⁾	Waldova statistika ⁽³⁾	p-value	Koeficient ⁽⁴⁾
Absolutní člen ⁽⁵⁾	6,6490	0,0099	-5,7827
L3	6,6947	0,0097	5,4316
CF/KZ	6,1589	0,0131	7,2714

⁽¹⁾ Logistic regression's output with $p = 0,05$; ⁽²⁾ Ratio;

⁽³⁾ Wald's statistics; ⁽⁴⁾ Coefficient; ⁽⁵⁾ Constant; Zdroj: vzorek podniků, vlastní zpracování


Tabulka 45 zachycuje hodnoty Waldovy statistiky (Waldova testového kritéria), charakteristické χ^2 rozdělením s jedním stupněm volnosti a testující statistickou významnost jednotlivých regresních koeficientů. Čím vyšší hodnoty dané testové kritérium nabývá, tím lze usuzovat na významnější koeficient. Dle výsledků odpovídajících p-value dochází při hladině významnosti $\alpha = 0,05$ k zamítnutí nulové hypotézy a prokázání významnosti všech koeficientů. Z lineární funkce $Z = -5,7827 + 5,4316 * L3 + 7,2714 * (CF/KZ)$ vyplývá následující předpis logistické funkce:

$$LR = \frac{1}{1 + e^{-(-5,7827 + 5,4316 * L3 + 7,2714 * \frac{CF}{KZ})}}$$

Dělicím bodem pro klasifikaci je v tomto případě hodnota **0,5**. V případě, že výsledek vyjde menší nebo roven 0,5, dochází k zařazení do skupiny úpadkových podniků. Při hodnotě větší než 0,5 je subjekt označen jako neúpadkový (prosperující).

Výsledná spolehlivost klasifikace tímto modelem v období jednoho roku před prohlášením úpadku dosáhla 96,55 %. Obrázek 2 ukazuje křivku ROC tohoto modelu, která popisuje tzv. trade-off efekt mezi senzitivitou a falešnou pozitivitou. Každý bod na křivce odpovídá jednomu dělicímu bodu. Čím více křivka směřuje k levému a hornímu okraji grafu, tím je ideálnější. Stejně tak ideální bod by odpovídal bodu [1;1]. Velikost plochy pod křivkou, vyjádřená indexem AUC je zde 0,98. Čím bližší je AUC jedné, tím dochází k lepší klasifikaci.

Obrázek 2: ROC křivka modelu LR⁽¹⁾



⁽¹⁾ ROC Curve of LR model; Horizontal axis = (1 – Specificity); Vertical axis = Sensitivity; Zdroj: vzorek podniků, vlastní zpracování, Statistica 12

9. 2. Ověření spolehlivosti a optimalizace dělicího bodu

Ověření úspěšnosti klasifikace vytvořeného modelu byla provedena metodou resubstituce. Výsledky zobrazuje tabulka 46. Na jejich základě lze poznamenat, že model lze uspokojivě využít pro předpověď úpadku s jednoletým předstihem. V tomto

časovém horizontu model vykazuje velmi vysokou spolehlivost, a sice 96,55 %. Tato úspěšná klasifikace 28 z 29 zástupců nastala při klasifikaci v obou skupinách, tedy skutečně bankrotní a skutečně nebankrotní.

Využitelnost modelu však značně klesá s prodlužující se dobou před úpadkem. Ve dvouletém předstihu dochází k pravdivé klasifikaci v pouhých 81,03 % případů, přičemž úspěšnější byl model při klasifikaci skutečně nebankrotních subjektů. Při snaze spolehlivě predikovat úpadek tři roky předem nastal ještě větší propad, a to na 70,69 %.

Tabulka 46: Spolehlivost modelu LR ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Senzitivita ⁽³⁾	Specifická ⁽⁴⁾	Spolehlivost ⁽⁵⁾
1	96,55%	96,55%	96,55%
2	86,21%	75,86%	81,03%
3	79,31%	62,07%	70,69%

⁽¹⁾ LR model's accuracy; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Sensitivity;

⁽⁴⁾ Specificity; ⁽⁵⁾ Accuracy; Zdroj: vzorek podniků, vlastní zpracování

Reakcí na neuspokojivé výsledky spolehlivosti predikce v období dvou a tří let před úpadkem je pokus o jejich zvýšení nalezením vhodnějšího dělicího bodu. První postup se zde shoduje s tím, který byl uplatněn v diskriminační analýze. To znamená, že každý výsledek modelu za období jednoho roku před úpadkem byl testován jako potenciální dělicí bod. Nová prahová hodnota, minimalizující chybné zařazení takto vyšla ve výši **0,4484**. Při její aplikaci však model zaznamenal ve všech letech shodnou spolehlivost.

Dále došlo k provedení téměř shodného postupu, avšak za možné dělicí body byly tentokrát zváženy výsledky modelu za časový horizont dvou let před úpadkem. Dělicí bod má v tomto případě hodnotu **0,5654**. Přes mírný pokles úspěšnosti predikce jeden rok předem přinesla aplikace nové prahové hodnoty žádoucí efekt, neboť průměrná spolehlivost modelu za dané tři časové horizonty se zvýšila na 83,91 %. Tabulka 47 prezentuje výsledky jednotlivých i celkové spolehlivosti za jednotlivá časová období před úpadkem:

Tabulka 47: Spolehlivost modelu LR - druhá optimalizace ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Senzitivita ⁽³⁾	Specifická ⁽⁴⁾	Spolehlivost ⁽⁵⁾
1	93,10%	96,55%	94,83%
2	86,21%	75,86%	81,03%
3	79,31%	72,41%	75,86%

⁽¹⁾ LR model's accuracy - second optimalization; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Sensitivity; ⁽⁴⁾ Specificity; ⁽⁵⁾ Accuracy; Zdroj: vzorek podniků, vlastní zpracování

Stejným způsobem byla otestována vhodnost výsledků modelu za období tří let před úpadkem. Dělicí bod zde vyšel ve výši **0,838**. Jeho použití pro klasifikaci přineslo další zvýšení průměrné spolehlivosti, kdy model zařazoval s úspěšností 86,78 %. Výsledky dílčích i celkové spolehlivosti za jednotlivé časové horizonty zobrazuje tabulka 48. Zní lze vidět, že model byl úspěšnější při klasifikaci skutečně bankrotních subjektů (true negatives) ve všech obdobích, přičemž s jednoletým předstihem zde předpovídá se 100% pravdivostí. Vůči původnímu dělicímu bodu však klesla spolehlivost klasifikace v období jednoho roku před prohlášením úpadku, zejména z důvodu snížení úspěšnosti ve skupině skutečně nebankrotních podniků (true positives). Tento fakt je kompenzován zvýšením spolehlivosti predikce za delší časové horizonty. Nový dělicí bod přináší ve srovnání s tím původním především zvýšení podílu pravdivě klasifikovaných entit za období tří let před úpadkem, konkrétně 82,76 % (zvýšení o 12,07 procentních bodů).

Tabulka 48: Spolehlivost modelu LR - třetí optimalizace ⁽¹⁾

Počet let před úpadkem ⁽²⁾	Senzitivita ⁽³⁾	Specifická ⁽⁴⁾	Spolehlivost ⁽⁵⁾
1	86,21%	100,00%	93,10%
2	79,31%	89,66%	84,48%
3	75,86%	89,66%	82,76%


⁽¹⁾ LR model's accuracy - third optimalization; ⁽²⁾ Years before bankruptcy; ⁽³⁾ Sensitivity; ⁽⁴⁾ Specificity; ⁽⁵⁾ Accuracy; Zdroj: vzorek podniků, vlastní zpracování

Poslední varianta optimalizace tedy přinesla dělicí bod 0,838, dle kterého model vychází při plnění funkce včasného varování s několikaletým předstihem nejúspěšněji. Klasifikační pravidlo je potom následovné. Hodnoty logistické funkce menší nebo rovné 0,838 odpovídají úpadkovým podnikům. Naopak při výsledku vyšším než 0,838 dochází ke klasifikaci mezi prosperující (neúpadkové) subjekty.

10. Srovnání spolehlivosti vytvořených a stávajících modelů

Graf 9 porovnává dosažené hodnoty spolehlivosti vytvořených a již existujících modelů, které byly v této práci ověřovány. Oba vytvořené modely obecně dosahují vysoké predikční úspěšnosti. Model LR poskytuje ze všech nejvyšší průměrnou spolehlivost, a to 86,78 %, což je o 0,57 procentních bodů vyšší než úspěšnost modelu LDF. V období jednoho a dvou let před prohlášením úpadku vykazují oba vytvořené modely shodnou spolehlivost, a to 93,10 % a 84,48 %. Při poskytnutí varování před možným úpadkem ve tříletém předstihu však model LR vykazuje vyšší úspěšnost (82,76 % oproti 81,03%). Ta je v tomto období shodná s Altmanovým Z'' , které rovněž vykazuje ze všech ověřovaných modelů nejvyšší diskriminační úspěšnost v období dvou let před úpadkem.

Graf 9: Srovnání spolehlivosti LR s LDF a ostatními stávajícími modely ⁽¹⁾



⁽¹⁾ Accuracy comparison of LR with LDF and other existing models; Horizontal axis = Model; Vertical axis = Accuracy; ⁽²⁾ 1 year before bankruptcy; ⁽³⁾ 2 years before bankruptcy; ⁽⁴⁾ 3 years before bankruptcy; ⁽⁵⁾ Average; Zdroj: vzorek podniků, vlastní zpracování

11. Závěr

Hlavním cílem této práce bylo vytvořit vlastní modely pro předpověď úpadku podniku pomocí diskriminační analýzy a logistické regrese a vyhodnotit jejich vlastnosti. Datovou základnou byl vzorek 29 úpadkových a 29 neúpadkových podniků, vybraných metodou párování. Subjekty pocházejí z odlišných odvětví, avšak splňují celoevropskou definici malých a středních podniků z hlediska počtu zaměstnanců.

Po počátečním vymezení teoretických východisek literární rešerší byla praktická část rozdělena na několik dílčích cílů. Nejprve došlo k zhodnocení klasifikační spolehlivosti devíti již existujících modelů. Úspěšnost, s jakou dokázaly zařadit jeden z 58 vybraných subjektů, byla ověřena za období jednoho až tří let před úpadkem. Nejvyšší průměrnou spolehlivost zde vykázal Altmanův model Z'' (85,63 %). S více než 80% průměrnou úspěšností rovněž predikoval model IN95 a Gurčíkův index. Následný pokus o nalezení vhodnější prahové hodnoty pro zařazení do jedné z binárních tříd, která by tyto spolehlivosti zvýšila, byl úspěšný pouze u několika modelů.

Další část spočívala v provedení tzv. profilové analýzy. Vývoj průměrných hodnot zvolených 28 poměrových ukazatelů pro obě skupiny, tedy bankrotních a nebankrotních podniků, byl nejdříve posouzen graficky. Navazovalo provedení testů shody středních hodnot těchto ukazatelů, ověřujících významné rozdíly ve vývoji ze statistického hlediska. Nejzřetelnější rozdílný vývoj prokázal oběma způsoby ukazatel rentability míra zisku. Ze statistického i grafického hlediska lze dále mezi nejvýznamnější ukazatele zařadit celkovou zadluženost nebo rentabilitu aktiv z cash flow. Profilová analýza se řadí do jednorozměrných metod. Již její autor (William Beaver) však připustil, že větší spolehlivost se dá předpokládat při použití vícerozměrného modelu, jehož tvorbou se zabývala následující část práce.

Na základě diskriminační analýzy byly dopřednou krokovou metodou vytvořeny čtyři varianty lineární diskriminační funkce, přičemž v každé z nich se minimálně jeden zahrnutý ukazatel lišil. Ověření jejich spolehlivosti za uvažované období jednoho až tří let před úpadkem metodou resubstituce označilo první model za nejúspěšnější (průměrná spolehlivost 77,01 %). Podíl pravdivě klasifikovaných subjektů však nebyl ani u tohoto modelu uspokojivý. Proto byly taktéž zde provedeny pokusy o nalezení vhodnějších dělicích bodů pro každý z těchto modelů. Jejich aplikace přinesla ve všech čtyřech případech žádoucí efekt, neboť došlo ke zvýšení predikční spolehlivosti. Nejvyšší nárůst byl zaznamenán u první varianty diskriminační funkce, a to o 9,20 procentních bodů na 86,21 %, což představovalo ze všech nejúspěšnější výsledek.

Z tohoto důvodu byl tento model s touto novou prahovou hodnotou vybrán jako finální. Zahrnuty jsou dvě nezávisle proměnné – míra zisku a běžná likvidita. Lze ho označit za relativně jednoduchý model, avšak vůči zbylým složitějším modelům stále nejspolehlivější.

Následně byl vytvořen model prostřednictvím logistické regrese. Dopředná kroková analýza i zde zahrnula dva poměrové ukazatele – běžnou likviditu a likviditu z cash flow. Posouzení spolehlivosti proběhlo rovněž metodou resubstituce. V období jednoho roku před úpadkem model správně klasifikoval 96,55 % případů. Spolehlivost v delším časovém horizontu však byla o poznání horší, a 81,03 % při predikci dva roky předem a 70,69 % v tříletém předstihu. Rovněž zde byl reakcí pokus o nalezení vhodnější hodnoty prahového bodu. Její aplikací a následným zhodnocením byl zjištěn pokles spolehlivosti predikce s jednoletým předstihem na 93,10%. Vůči tomu však došlo ke zlepšení úspěšnosti v horizontu dvou let před úpadkem, a to na 84,48 %. Razantní zlepšení vyšlo v období tří let před úpadkem, kdy model dosáhl 82,76% spolehlivosti (o 12,07 procentních bodů vyšší než při původním dělícím bodu).

Sestavením těchto modelů diskriminační analýzou a logistickou regresí, byl naplněn cíl práce. Využitelnost těchto modelů odpovídá charakteru vybraného vzorku podniků. S tím souvisí další obecné omezení, a to možný pokles spolehlivosti při použití na jiné subjekty, než na kterých byly modely vytvořeny. To dokazují zde vypočítané výsledky klasifikační úspěšnosti stávajících modelů. Pokud zkonstruované modely projeví při budoucí aplikaci obdobné hodnoty predikční spolehlivosti, přispějí včasnějšímu odhalení hrozícího úpadku. Podniky tak budou moci po zjištění příčin vhodně reagovat a omezit tak nepříznivý dopad finančních problémů na sebe i ostatní ovlivněné subjekty.

Summary and keywords

The main aim of this master thesis is to create own models for enterprise bankruptcy prediction by using discriminant analysis and logistic regression and to assess their qualities. The fundamental task of predictive models is to provide an early-warning system which would give important information about threatening bankruptcy. All of the selected enterprises correspond to the EU definition of small and medium enterprises by number of employee and are not limited by any particular industry. The sample contains 29 entities characteristic by bankruptcy declaration in 2012-2015 time period and 29 matched successful entities.

At first, an assessment of several existing classification models was performed. By evaluating predictive accuracy in each of one to three years before bankruptcy declaration, the Altman's Z'' model turned out to be the most successful, with average reliability of 85,63%. Models IN95 and Gurčik's index also proved very high accuracy. Profile analysis was performed afterwards. 28 Selected ratios and their average values for each of three years before bankruptcy were calculated. Assessing development for both the bankruptcy and non-bankruptcy enterprises by graphs and the statistical t-test for equality of means provided the highest significance and discrimination ability for the ratios Earnings Before Tax/Total Assets or Debt ratio.

Four linear discriminant functions were constructed by applying forward stepwise selection method of discriminant analysis. Primary results of accuracy assessment were not satisfying enough. In order to increase their predictive ability, new eligible threshold values for classification were found and applied. The highest reliability (86,21 %) proved the first created model, including two ratios –Earnings Before Tax/Total Assets and Current Liquidity. Logistic regression, also performed by using forward stepwise selection method, resulted in logistic function including these two ratios: Current Liquidity and Cash Flow Liquidity. This model, also with optimized threshold value, provided even higher average predictive accuracy (86,78 %). In comparison with existing models analyzed in this thesis, the best classification reliability provided logistic regression model. Discriminant analysis model predicted with the same average reliability as Altman's model Z'' .

Key words: Predictive models, Discriminant analysis, Logistic regression

Seznam literatury

1. Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589-609. doi:10.1111/j.1540-6261.1968.tb00843.x
2. Altman, E. I. (2000). *Predicting Financial Distress of Companies: Revisiting the Z-Score and Zeta Models*. NY: New York University Salomon Center
3. Altman, E. I., & Hotchkiss, E. (2006). *Corporate financial distress and bankruptcy: Predict and avoid bankruptcy, analyze and invest in distressed debt* (3rd ed.). Hoboken: Wiley & Sons.
4. Anděl, J. (1998). *Statistické metody* (2nd Ed.). Praha: Matfyz press.
5. Balcaen, S., & Ooghe, H. (2006). 35 years of studies on business failure: an overview of the classic statistical methodologies and their related problems. *The British Accounting Review*, 38(1), 63-93. doi:10.1016/j.bar.2005.09.001
6. Barvenčík, O. (2010). *Statistické klasifikační metody*. (Diplomová práce, Vysoké učení technické, Brno, Česká republika). Retrieved from: <https://dspace.vutbr.cz/bitstream/handle/11012/16384/barvencik.pdf?sequence=2>
7. Beaver, W. H. (1966). Financial Ratios as Predictors of Failure. *Journal of Accounting Research*, 4(1), pp. 71-111. doi: 10.2307/2490171
8. Bellovary, J. L., Giacomino, D. E., & Akers, M. D.. (2007). A Review of Bankruptcy Prediction Studies: 1930 to Present. *Journal of Financial Education*, 33, 1–42. Retrieved from <http://www.jstor.org/stable/41948574>
9. Blaha, Z. S., & Jindřichovská, I. (2006). *Jak posoudit finanční zdraví firmy*. Praha: Management Press.
10. Bortlíček, Z. (2008). *ROC křivky*. (Diplomová práce, Masarykova univerzita, Brno, Česká republika). Retrieved from: http://is.muni.cz/th/106210/prif_m/Diplomova_prace.pdf
11. Česká republika. (2006). Zákon č. 182/2006 Sb., o úpadku a způsobech jeho řešení. In: *Sbírka zákonů*. Česká republika
12. Fawcett, T. (2006). An introduction to ROC analysis. *Pattern recognition letters*, 27(8), 861-874. doi:10.1016/j.patrec.2005.10.010
13. Fight, A. (2004). *Credit risk management*. London: Elsevier Butterworth-Heinemann.
14. Grice, J. S., & Dugan, M. T. (2001). The limitations of bankruptcy prediction models: Some cautions for the researcher. *Review of Quantitative Finance and Accounting*, 17(2), 151-166. doi: 10.1023/A:1017973604789
15. Grünwald, R., & Holečková, J. (2009). *Finanční analýza a plánování podniku*. Praha: Ekopress.

16. Gurčík, L'. (2002). G-index – metóda predikcie finančného stavu poľnohospodárskych podnikov, *Agricultural Economics*, 48(8), pp. 373-387.
17. Havránek, T., & Vorlíček, J. (1980). *Lineární diskriminační funkce*. In: ROBUST '80. Praha: JČMF.
18. Hebák, P. (2007a). *Vícerozměrné statistické metody [1]*. (2nd Ed.). Praha: Informatorium
19. Hebák, P. (2007b). *Vícerozměrné statistické metody [3]*. Praha: Informatorium
20. Hendl, J. (2006). *Přehled statistických metod zpracování dat: analýza a metaanalýza dat*. (2nd Ed.). Praha: Portál
21. Hendl, J. (2009). *Přehled statistických metod: analýza a metaanalýza dat*. (3rd Ed.) Praha: Portál
22. Hrochová, M. (2014). Levenův test shodnosti rozptylů. (Bakalářská práce, Univerzita Karlova, Praha, Česká republika). Retrieved from: <https://is.cuni.cz/webapps/zzp/detail/139695/>
23. Chráška, M. (2007). *Metody pedagogického výzkumu: základy kvantitativního výzkumu*. (1st Ed.). Praha: Grada.
24. Holečková, J. (2008). *Finanční analýza firmy*. (1st Ed.). Praha: ASPI.
25. Jackson, R. H., & Wood, A. (2013). The performance of insolvency prediction and credit risk models in the UK: A comparative study. *The British Accounting Review*, 45(3), 183-202. doi: 10.1016/j.bar.2013.06.009
26. Knápková, A., Pavelková, D., Šteker, K. (2013). *Finanční analýza: Komplexní průvodce s příklady*. (2nd Ed.). Praha: Grada Publishing.
27. Kumar, P. R., & Ravi, V. (2007). Bankruptcy prediction in banks and firms via statistical and intelligent techniques—A review. *European journal of operational research*, 180(1), 1-28. doi: 10.1016/j.ejor.2006.08.043
28. Marek, P. (2006). *Studijní průvodce financemi podniku*. Praha: Ekopress
29. Maršíková, J. (2011). *Insolvenční řízení z pohledu dlužníka a věřitele: příručka zejména pro právníky*. (2nd Ed.). Praha: Linde Praha.
30. Meloun, M., & Militký, J. (2006). *Kompendium statistického zpracování dat: metody a řešené úlohy*. (2nd Ed.). Praha: Academia
31. Mrkvička, J., & Kolář, P. (2006). *Finanční analýza*. (2nd Ed.). Praha: ASPI
32. Neumaierová, I., & Neumaier, I. (2002). *Výkonnost a tržní hodnota firmy*. Praha: Grada Publishing a.s.
33. Neumaierová, I., & Neumaier, I. (2005). *Index IN05*. In: *Sborník příspěvků z mezinárodní vědecké konference Evropské finanční systémy*. Brno: Masarykova univerzita.
34. Neumaierová, I., & Neumaier, I. (2008). Proč se ujal index IN a nikoli pyramidový systém ukazatelů INFA, *Ekonomika a management*, 2(4).

35. Neumaier, I., & Neumaierová, I. (2014). INFA Performance Indicator Diagnostic System. *Central European Business Review*, 3(1), 35-41. doi: 10.18267/118
36. Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), pp. 109-131. doi: 10.2307/2490395
37. Ratner, B. (2012). *Statistical and machine-learning data mining: techniques for better predictive modeling and analysis of big data*. (2nd ed.). Boca Raton: Taylor & Francis
38. Rencher, A. C. (2003). *Methods of multivariate analysis*. Hoboken: John Wiley & Sons.
39. Rychlý, M. (2003). Klasifikace a predikce. Ústav informačních systémů, VUT Brno. Retrieved from: <http://www.fit.vutbr.cz/~rychly/docs/classification-and-prediction/classification-and-prediction.pdf>
40. Rýdl, T. (2005). Vliv úpadkového práva na finanční stabilitu. In: *Zpráva o finanční stabilitě* (pp. 93-101). Retrieved from: https://www.cnb.cz/miranda2/export/sites/www.cnb.cz/cs/financni_stabilita/zpravy_fs/fs_2005/FS_2005.pdf
41. Sedláček, J. (2011). *Finanční analýza podniku* (2nd Ed.). Brno: Computer Press
42. Synek, M. (2007). *Manažerská ekonomika*. (4th Ed.) Praha: Grada Publishing.
43. Tabachnick, B., & Fidell, L. (2007). *Using multivariate statistics*. (5th ed.). Boston, MA: Pearson/A&B.
44. Valach, J. (2010). *Investiční rozhodování a dlouhodobé financování*. (3rd Ed.). Praha: Ekopress.
45. Zdeněk, R. (2012). Predikce finanční tísně podniku. (Disertační práce, Jihočeská Univerzita, České Budějovice, Česká republika). Retrieved from: <https://wstag.jcu.cz/StagPortletsJSR168/KvalifPraceDownloadServlet?typ=1&adipidno=18306>
46. Zmijewski, M.E. (1984). Methodological issues related to the estimation of financial distress pre-diction models. *Journal of Accounting Research*, 22(1), pp. 59 – 86. doi: 10.2307/2490859

Seznam tabulek, grafů a obrázků

Seznam tabulek

Tabulka 1: Klasifikační matice	30
Tabulka 2: Klasifikační matice - Altmanovo Z' - 1 rok před úpakem	42
Tabulka 3: Klasifikační matice - Altmanovo Z' - 2 roky před úpadkem	42
Tabulka 4: Klasifikační matice - Altmanovo Z' - 3 roky před úpadkem	43
Tabulka 5: Optimalizace - Altmanovo Z' - spolehlivost	44
Tabulka 6: Klasifikační matice - Altmanovo Z'' - 1 rok před úpadkem	45
Tabulka 7: Klasifikační matice - Altmanovo Z'' - 2 roky před úpadkem	46
Tabulka 8: Klasifikační matice - Altmanovo Z'' - 3 roky před úpadkem	47
Tabulka 9: Optimalizace - Altmanovo Z'' - spolehlivost	47
Tabulka 10: Klasifikační matice - IN95 - 1 rok před úpadkem	48
Tabulka 11: Klasifikační matice - IN95 - 2 roky před úpadkem	49
Tabulka 12: Klasifikační matice - IN95 - 3 roky před úpadkem	49
Tabulka 13: Optimalizace - IN95 – spolehlivost	50
Tabulka 14: Klasifikační matice - IN99 - 1 rok před úpadkem	51
Tabulka 15: Klasifikační matice - IN99 - 2 roky před úpadkem	52
Tabulka 16: Klasifikační matice - IN99 - 3 roky před úpadkem	52
Tabulka 17: Optimalizace - IN99 – spolehlivost	53
Tabulka 18: Klasifikační matice - IN01 - 1 rok před úpadkem	54
Tabulka 19: Klasifikační matice - IN01 - 2 roky před úpadkem	54
Tabulka 20: Klasifikační matice - IN01 - 3 roky před úpadkem	55
Tabulka 21: Optimalizace - IN01 – spolehlivost	56
Tabulka 22: Klasifikační matice - IN05 - 1 rok před úpadkem	56
Tabulka 23: Klasifikační matice - IN05 - 2 roky před úpadkem	57
Tabulka 24: Klasifikační matice - IN05 - 3 roky před úpadkem	57
Tabulka 25: Optimalizace - IN05 – spolehlivost	58
Tabulka 26: Klasifikační matice - Tafflerův základní model - 1 rok před úpadkem	58
Tabulka 27: Klasifikační matice - Tafflerův základní model - 2 roky před úpadkem	59
Tabulka 28: Klasifikační matice - Tafflerův základní model - 3 roky před úpadkem	60
Tabulka 29: Optimalizace -Taffler základní model – spolehlivost	60

Tabulka 30: Klasifikační matice - Tafflerův modifikovaný model - 1 rok před úpadkem	61
Tabulka 31: Klasifikační matice - Tafflerův modifikovaný model - 2 roky před úpadkem	62
Tabulka 32: Klasifikační matice - Tafflerův modifikovaný model - 3 roky před úpadkem	62
Tabulka 33: Optimalizace - Taffler modifikovaný model – spolehlivost	63
Tabulka 34: Klasifikační matice - Gurčíkův index - 1 rok před úpadkem	64
Tabulka 35: Klasifikační matice - Gurčíkův index - 2 roky před úpadkem	64
Tabulka 36: Klasifikační matice - Gurčíkův index - 3 roky před úpadkem	65
Tabulka 37: Optimalizace - Gurčíkův index – spolehlivost	66
Tabulka 38: Vyhodnocení optimalizace - dělicí body a spolehlivost	68
Tabulka 39: Průměrné hodnoty a p-value vybraných ukazatelů	75
Tabulka 40: Kolmogorov-Smirnovovy testy	77
Tabulka 41: Korelační matice vybraných ukazatelů	79
Tabulka 42: Faktorové strukturní koeficienty LDF1	79
Tabulka 43: Klasifikační matice - LDF1 - 1 rok před úpadkem	80
Tabulka 44: Optimalizace vytvořených modelů - dělicí body a spolehlivost	84
Tabulka 45: Výstup logistické regrese při $p=0,05$	86
Tabulka 46: Spolehlivost modelu LR	88
Tabulka 47: Spolehlivost modelu LR - druhá optimalizace	89
Tabulka 48: Spolehlivost modelu LR - třetí optimalizace	89

Seznam grafů

Graf 1: Celkové i dílčí chybovosti Altmanova Z' pro jednotlivé dělicí body	44
Graf 2: Spolehlivost stávajících modelů	67
Graf 3: Vývoj VHD/A bankrotních a nebankrotních podniků	70
Graf 4: Vývoj KZ/V bankrotních a nebankrotních podniků	71
Graf 5: Vývoj ČPK/A bankrotních a nebankrotních podniků	72
Graf 6: Vývoj OsN/V bankrotních a nebankrotních podniků	73
Graf 7: Vývoj CF/A bankrotních a nebankrotních podniků	74
Graf 8: Spolehlivost vytvořených diskriminačních funkcí	83
Graf 9: Srovnání spolehlivosti LR s LDF a ostatními stávajícími modely	90

Seznam obrázků

Obrázek 1: Křivka ROC	31
Obrázek 2: ROC křivka modelu LR	87

Seznam zkratk a symbolů

B = bankrotní

CF/A = rentabilita aktiv z cash flow

CF/CK = stupeň oddlužení

CF/KZ = likvidita z cash flow

CF/V = rentabilita výnosů z cash flow

ČPK/A = podíl čistého pracovního kapitálu na aktivech

ČPK/V = podíl čistého pracovního kapitálu na výnosech

DLR = dlouhodobá rentabilita

KCK/A = krátkodobá zadluženost

KZ/V = vázanost krátkodobých závazků

L3 = běžná likvidita

L2 = pohotová likvidita

L1 = peněžní likvidita

LDF = lineární diskriminační funkce

LR = logistická regrese

NB = nebankrotní

OA/CK = krytí cizího kapitálu oběžným majetkem

OA/V = vázanost oběžných aktiv

OsN/V = mzdová nákladovost

RDZ = rentabilita dlouhodobých zdrojů

V/A = účinnost celkových aktiv

VH/VK = rentabilita vlastního kapitálu

VHD/A = míra zisku

VHD/V = rentabilita výnosů

VHD/KCK = podíl výsledku hosp. před zdaněním na krátkodob. cizích zdrojích

VHML/A = podíl výsledku hospodaření minulých let na aktivech

VHÚD/A = rentabilita celkové kapitálu

VHÚD/NÚ = úrokové krytí

VK/A = koeficient samofinancování

VS/V = nákladovost výkonové spotřeby

Z/V = vázanost zásob

Seznam příloh

Příloha 1: Grafické provedení profilové analýzy – vybrané ukazatele

Přílohy

Příloha 1: Grafické provedení profilové analýzy – vybrané ukazatele

