

UNIVERZITA KARLOVA V PRAZE

FAKULTA SOCIÁLNÍCH VĚD

INSTITUT EKONOMICKÝCH STUDIÍ

DIPLOMOVÁ PRÁCE

2002

MARKÉTA ŠLAISOVÁ

UNIVERZITA KARLOVA V PRAZE

FAKULTA SOCIÁLNÍCH VĚD

INSTITUT EKONOMICKÝCH STUDIÍ

Diplomová práce

DISKRIMINAČNÍ ANALÝZA V MANAGEMENTU ÚVĚROVÁNÍ

Vypracovala: Markéta Šlaisová

Konzultant: Prof. Ing. Michal Mejstřík, CSc.

Akademický rok: 2001/2002

## Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně a použila pouze uvedené prameny a literaturu.

V Praze dne 6. 5. 2002

Markéta Šlaisová

## Poděkování

Ráda bych na tomto místě vyjádřila poděkování všem, kteří byli ochotni podělit se o informace týkající se zpracované problematiky.

Zvláštní poděkování patří mému konzultantovi Prof. Ing. Mejstříkovi za významné rady a firmě EEIP, a.s. za vytvoření podmínek pro sběr dat.

## Abstrakt

Tato práce je zaměřena na ohodnocení možností zefektivnění tuzemského managementu úvěrování, které může přinést systemizace úvěrových rozhodnutí na základě metody vícerozměrné diskriminační analýzy (MDA). Posouzení metody vychází ze srovnání požadavků MDA na rysy prostředí s podmínkami, jejichž splnění je nutné pro využití nástrojů navrhovaných Novou basilejskou dohodou o kapitálové přiměřenosti – tzv. interních modelů řízení úvěrového rizika. Vedle kritéria dostupnosti požadovaných dat je MDA hodnocena i z hlediska schopnosti pružné reakce na změny prostředí, především posuny v bonitní struktuře populace bankovních klientů a v relacích nákladů různých chybných rozhodnutí. Stěžejní část práce pak tvoří soubor vlastních empirických aplikací MDA, vycházejících ze zhodnocení vybraných předchozích studií zabývajících se vysvětlením finanční tísně pomocí MDA. Analýzy jsou vedle cíle zodpovězení otázky, zda je v současných českých podmínkách možné s použitím MDA identifikovat determinanty úpadku společnosti, orientovány také se na testování některých sporných předpokladů, kladených implicitně autory předešlých studií. Jedná se především o předpoklad neměnnosti diskriminačních koeficientů v čase. Jeho splnění či nesplnění má totiž významný vliv na možnost vytvoření „univerzální diskriminační funkce“, schopné vysvětlit finanční situaci, respektive úroveň úvěrového rizika podniků v jakémkoli období.

## Abstract

This paper focuses on the assessment of options for enhancing the efficiency of credit management in Czech banks that can be achieved through systematic approach to credit decisions based on multiple discriminant analysis (MDA). The method's requirements on features of the analyzed environment are assessed and compared to the prerequisites of methods, proposed by the New Basle Capital Accord – the internal models of credit risk assessment. Besides the data requirements criterion, MDA is rated from the perspective of flexibility of adaptation to changes in the environment, above all concerning the bonity structure of the bank's clients and the relative costs of banks' incorrect decisions. A fundamental part of the paper consists of a set empirical applications of MDA, which build on the reviews of selected previous papers on assessment of financial distress via MDA. Besides the evaluation of the possibility to identify the determinants of business failure in current Czech conditions by the means of MDA, the analyses performed within this paper also aim at testing some of the questionable assumptions, which have been imposed implicitly by the authors of the previous papers. This concerns in particular the assumption that discriminant coefficients are constant over time, the fulfillment of which is of fundamental importance for the feasibility of a "universal discriminant function" that would explain financial distress and/or credit risk of enterprises at any point of time.

## ÚVOD

Český bankovní sektor prošel v posledním desetiletí velmi nákladným procesem konsolidace. Rozsáhlé problémy, které byly impulsem pro tento proces, byly výsledkem působení hned několika negativních vlivů. Jednu část kořenů problémů lze hledat již ve struktuře bankovního sektoru před zahájením ekonomické transformace a zatíženosti portfolií následnických bank Státní banky československé. Za další vliv bývá označován všeobecný nedostatek jiných než úvěrových forem financování, který vyvolal zvýšenou závislost bank na ekonomickém úspěchu úvěrovaných firem. Důležitou roli v tvorbě rizikového profilu českého bankovníctví sehrála skutečnost, že banky neměly k dispozici ani zavedené systémy posuzování bonity klientů ani dostatek informací o úvěrovaných subjektech. Vznikl tak prostor pro morální hazard nejen ze strany podniků poptávajících úvěrování, ale i ze strany manažerů bank, orientovaných v takto netransparentním prostředí na plnění krátkodobých a osobních cílů.

Při zkoumání charakteru a výsledků programů, zaměřených na potlačení růstu úvěrového rizika, jsem si položila několik otázek: Je „metoda pokusu a omylu“ tou správnou cestou k vytvoření postupu měření úvěrového rizika? Existuje způsob, jak lze vysokým nákladům řešení již rozbujelých problémů s úvěrovým rizikem systematicky předcházet? Jaké metody jsou k tomuto účelu používány ve vyspělých ekonomikách? Je již tuzemské prostředí natolik stabilní, aby bylo možné vypořádat v něm důležité závislosti a založit na nich management úvěrování? Je diskriminační analýza, používaná v řadě zahraničních bank, metodou vhodnou pro hledání těchto závislostí?

Přání nalézt odpověď na tyto otázky mě vedlo k výběru tématu diplomové práce. Pokusila jsem se v jejím rámci vymezit škálu přístupů k řízení úvěrového rizika, zhodnotit, jaké pojetí dosud převládalo v českém bankovníctví, a v neposlední řadě přispět k prozkoumání možností zefektivnění postupů managementu úvěrování vlastní empirickou analýzou zaměřenou na možnost předvídání finanční tísně pomocí diskriminační metody.

První kapitola je v duchu tohoto postupu věnována nástinu základních skupin nástrojů managementu úvěrování - od posouzení úvěrové žádosti a stanovení vhodné úrokové míry přes zajištění úvěru po diverzifikaci portfolia a využití zajišťovacích instrumentů. V ohnisku zájmu celé práce jsou metody odhadu rizikovosti klientů, jejichž zvládnutí považuji za důležitý předpoklad fungování managementu úvěrování. Po stručném shrnutí celé škály nástrojů se proto zaměřím právě na tuto oblast. Pokusím se vymezit a zhodnotit oblasti vhodného použití dvou krajních přístupů k posouzení bonity: přístupu založeného na individuální analýze úvěrové žádosti na straně jedné a postupech zaměřených na hledání podobností a odhalení rysů struktury klientů na straně druhé.

Abych naznačila rozsah problémů, jakým může být bankovní sektor vystaven, pokud koncepční metoda managementu úvěrování chybí, rozhodla jsem se nastínit v druhé kapitole charakter a výsledky programů, zahájených s cílem vyřešit již rozbujelé problémy s řízením úvěrového rizika.

V rámci této kapitoly dále posoudím možnosti systemizace managementu úvěrování v kontextu začleňování českého bankovního sektoru do světového finančnictví. Zvážím v této souvislosti především rozměr, který dává řízení úvěrového rizika rámec regulace navržený Novou basilejskou dohodou o kapitálové přiměřenosti. Zhodnotím rovněž prostor, který bankám poskytne vytvoření centrálních registrů dlužníků.

V rámci dalších kapitol se již zaměřím přímo na zkoumání možností, které systemizaci řízení úvěrového rizika přináší metoda vícerozměrné diskriminační analýzy (MDA<sup>1</sup>):

Kapitola třetí přiblíží prostor pro využití MDA v managementu úvěrování na teoretické rovině. Po shrnutí obecného modelu se zaměřím na způsoby testování a využití jejích výsledků, dále pak na možnosti zohlednění specifické struktury dat a rozdílných nákladů různých chyb klasifikace.

Shrnutí způsobu a výsledků dosavadního výzkumu využití statistických metod pro modelování finančního zdraví firem je obsahem čtvrté kapitoly. Zhodnotím pouze studie, které představují z hlediska cíle této práce ve výzkumu aplikace MDA ve finančnictví důležité milníky. V návaznosti na cíle a výsledky těchto studií se zamyslím nad hranicemi přenositelnosti funkcí, vysvětlujících rozdíly mezi skupinami firem, v čase a prostoru.

Na rozbor výsledků vybraných studií a zmíněnou úvahu o omezeních přenášení vysvětlujících funkcí z prostředí na prostředí naváží vlastní aplikaci MDA na data o českých podnicích, zařazenou do páté kapitoly. Cílem analýz, jejichž výsledky budu v rámci této kapitoly prezentovat, bylo především zhodnotit, do jaké míry je možné modelovat finanční situaci českých podniků pomocí lineární diskriminační funkce, založené na informacích z finančních výkazů. Dalším dílčím cílem empirické analýzy, uvedené v páté kapitole, bylo přispět k prozkoumání vhodnosti předpokladu často implicitně kladeného autory předchozích studií,<sup>2</sup> a to předpokladu neměnnosti koeficientů diskriminační funkce v čase. Za účelem jeho ověření jsem provedla analýzy vlivu ukazatelů na členění do skupin v různých časových okamžicích.

Abych přispěla k testování výše uvedené hypotézy o omezené přenositelnosti funkcí z prostředí na prostředí, zařadila jsem do páté kapitoly také porovnání závěrů vlastní analýzy s výsledky jiných studií, provedené na základě srovnání výsledků testů klasifikační schopnosti jednotlivých funkcí získané jejich aplikací na stejná data.

Závěry, které prezentuji v rámci zprávy o praktické části své diplomové práce, je podle mého názoru nutné posuzovat s ohledem na rozsah vzorku dat, který jsem měla k dispozici. Z tohoto hlediska považuji jejich srovnání s výsledky dalších empirických analýz, provedených na širší datové základně, za velmi přínosné. V následujícím textu průběžně uvádím další náměty na zhodnocení výsledků své práce jejich srovnáním se závěry alternativních studií, zaměřených na modelování finanční tísně pomocí jiných metod a jiného typu vstupních proměnných. Ve skládání výsledků

---

<sup>1</sup> Z anglického „Multiple Discriminant Analysis“.

<sup>2</sup> Např. Altman (1968), Sinkey (1975) nebo Buchtíková (1998, resp. 1999).

různých prací na toto téma vidím cestu k vytipování přínosů a překážek využití různých metod systemizace měření úvěrového rizika, a tedy i k nalezení nástroje vhodného pro dané prostředí.



**OBSAH**

<b>1.</b>	<b><u>STANDARDNÍ NÁSTROJE ŘÍZENÍ ÚVĚROVÉHO RIZIKA</u></b>	<b>8</b>
1.1.	<u>ZÁKLADNÍ SKUPINY NÁSTROJŮ</u>	8
1.1.1.	<u>Ocenění úvěru</u>	8
1.1.2.	<u>Selektivní přidělování úvěrů</u>	9
1.1.3.	<u>Zajištění zástavou</u>	10
1.1.4.	<u>Diverzifikace a hedging</u>	10
1.2.	<u>ODHADY PLATEBNÍ DISCIPLÍNY JAKO PŘEDPOKLAD ÚSPĚŠNÉHO ÚVĚROVÁNÍ</u>	10
1.2.1.	<u>Přístupy k ohodnocení bonity klienta</u>	10
1.2.1.1.	<u>Tradiční přístup</u>	11
1.2.1.2.	<u>Nový přístup</u>	13
1.2.1.2.1.	<u>Výhody a nevýhody jednotlivých metod nového přístupu</u>	14
1.3.	<u>ZÁVĚR</u>	15
<b>2.</b>	<b><u>SITUACE V ČESKÉM BANKOVNICTVÍ</u></b>	<b>16</b>
2.1.	<u>PROGRAMY KONSOLIDACE – ŘEŠENÍ EX POST</u>	16
2.1.1.	<u>Konsolidační program I</u>	17
2.1.2.	<u>Konsolidační program II</u>	17
2.1.3.	<u>Stabilizační program</u>	18
2.1.4.	<u>Čištění portfolií bank před jejich privatizací</u>	18
2.2.	<u>PROSTOR PRO ŘEŠENÍ EX ANTE</u>	19
2.2.1.	<u>Nová basilejská dohoda a interní modely řízení úvěrového rizika</u>	19
2.2.2.	<u>Modely založené na ratingu</u>	20
2.2.3.	<u>Interní modely tuzemských komerčních bank</u>	21
2.2.3.1.	<u>Podmínky tvorby vlastních modelů</u>	22
2.3.	<u>ZÁVĚR</u>	24
<b>3.</b>	<b><u>METODOLOGIE MDA</u></b>	<b>25</b>
3.1.	<u>TEORETICKÉ ZÁKLADY DISKRIMINAČNÍ FUNKCE</u>	25
3.1.1.	<u>Obecný model diskriminační analýzy</u>	25
3.2.	<u>VYUŽITÍ VÝSLEDKŮ MDA PRO MĚŘENÍ ÚVĚROVÉHO RIZIKA</u>	29
3.2.1.	<u>Predikce finančního zdraví</u>	29
3.2.1.1.	<u>Praktické ověření schopnosti klasifikace</u>	30
3.2.1.1.1.	<u>Empirická metoda</u>	30
3.2.1.1.2.	<u>Křížová metoda</u>	30
3.2.1.1.3.	<u>Metoda kapesního nože</u>	31
3.2.1.2.	<u>Zohlednění specifických rysů prostředí</u>	31
3.2.1.2.1.	<u>Pravděpodobnost a priori</u>	32
3.2.1.2.2.	<u>Náklady chybné klasifikace</u>	33
3.2.2.	<u>Vytipování důležitých proměnných</u>	37
3.3.	<u>ZÁVĚR</u>	38

<b>4.</b>	<b><u>MDA V PŘEDCHOZÍCH EMPIRICKÝCH STUDIÍCH</u></b> .....	<b>39</b>
4.1.	<u>JEDNOROZMĚRNÁ ANALÝZA DAT Z AMERICKÉ EKONOMIKY</u> .....	39
4.2.	<u>VÍCEROZMĚRNÁ ANALÝZA DAT Z AMERICKÉ EKONOMIKY</u> .....	40
4.2.1.	<u>Motivace analýzy</u> .....	40
4.2.2.	<u>Výběr dat a průběh analýzy</u> .....	41
4.2.3.	<u>Výsledky analýzy</u> .....	41
4.3.	<u>HRANICE PŘENOSITELNOSTI MODELŮ</u> .....	44
4.3.1.	<u>Rozdílné podmínky v různých ekonomikách</u> .....	44
4.3.2.	<u>Definice kritéria diskriminace</u> .....	45
4.4.	<u>VÍCEROZMĚRNÁ ANALÝZA DAT Z ČESKÉ EKONOMIKY</u> .....	45
4.5.	<u>ZÁVĚR</u> .....	47
<b>5.</b>	<b><u>EMPIRICKÁ STUDIE FINANČNÍ SITUACE ČESKÝCH PODNIKŮ</u></b> .....	<b>49</b>
5.1.	<u>POPIS PŘÍKLADU</u> .....	49
5.2.	<u>VÝBĚR PROMĚNNÝCH A NÁSLEDNÉ ÚPRAVY</u> .....	50
5.2.1.	<u>Výběr kritéria diskriminace</u> .....	50
5.2.1.1.	<u>Diskuse vhodnosti zvoleného kritéria diskriminace</u> .....	50
5.2.2.	<u>Výběr nezávisle proměnných</u> .....	51
5.2.2.1.	<u>Zvolené vstupy a diskuse jejich očekávaného vlivu</u> .....	51
5.2.2.1.1.	<u>Ukazatele likvidity</u> .....	52
5.2.2.1.2.	<u>Ukazatele rentability a ziskovosti</u> .....	54
5.2.2.1.3.	<u>Ukazatele aktivity</u> .....	57
5.2.2.1.4.	<u>Ukazatele zadluženosti</u> .....	59
5.2.3.	<u>Výběr vzorku</u> .....	60
5.2.4.	<u>Diskuse struktury dat a její úpravy</u> .....	61
5.2.4.1.	<u>Rozdíly ve velikosti firem</u> .....	62
5.2.4.2.	<u>Diskuse předpokladů aplikace MDA</u> .....	62
5.2.4.2.1.	<u>Náhodnost výběru a normalita rozdělení</u> .....	62
5.2.4.2.2.	<u>Korelace mezi proměnnými</u> .....	63
5.2.4.2.3.	<u>Shodnost kovariančních matic</u> .....	64
5.3.	<u>VÝSLEDNÉ MODELY</u> .....	66
5.3.1.	<u>Analýza 1: jeden rok před konkursem</u> .....	66
5.3.2.	<u>Analýza 2: dva roky před konkursem</u> .....	73
5.3.3.	<u>Analýza 3: obě období před konkursem</u> .....	77
5.4.	<u>SROVNÁNÍ VÝSLEDKŮ VLASTNÍCH ANALÝZ S REFERENČNÍMI MODELY</u> .....	81
5.4.1.	<u>Srovnání výsledků testů klasifikační schopnosti empirickou metodou</u> .....	81
5.4.2.	<u>Srovnání výsledků testů klasifikační schopnosti křížovou metodou</u> .....	82
5.4.3.	<u>Porovnání vhodnosti modelů pro vysvětlení finančních potíží českých podniků</u> ..	84
<b>6.</b>	<b><u>ZÁVĚR</u></b> .....	<b>88</b>
	<b><u>POUŽITÁ LITERATURA</u></b> .....	<b>91</b>
	<b><u>TEZE DIPLOMOVÉ PRÁCE</u></b> .....	<b>93</b>
	<b><u>PŘÍLOHY</u></b> .....	<b>95</b>

## SEZNAM TABULEK UVEDENÝCH V TEXTU

<b><u>tabulka 1</u></b>	<b><u>Klasifikační matice pro rozdělení do skupin „Ztrátový“ a „Bonitní“</u></b> .....	29
<b><u>tabulka 2</u></b>	<b><u>Strategie zamezení chybám klasifikace</u></b> .....	36
<b><u>tabulka 3</u></b>	<b><u>Shrnutí proměnných zahrnutých do modelu při Analýze 1</u></b> .....	67
<b><u>tabulka 4</u></b>	<b><u>Standardizované koeficienty plynoucí z výsledné funkce Analýzy 1</u></b> .....	68
<b><u>tabulka 5</u></b>	<b><u>Klasifikační matice výsledné funkce Analýzy 1 – test na primárních datech</u></b> ...	70
<b><u>tabulka 6</u></b>	<b><u>Klasifikační funkce plynoucí z Analýzy 1</u></b> .....	71
<b><u>tabulka 7</u></b>	<b><u>Klasifikační matice výsledné funkce analýzy 1 – test na sekundárních datech</u></b> . 72	
<b><u>tabulka 8</u></b>	<b><u>Shrnutí proměnných zahrnutých do modelu při Analýze 2</u></b> .....	74
<b><u>tabulka 9</u></b>	<b><u>Klasifikační matice výsledné funkce analýzy 2 – test na primárních datech</u></b> ....	75
<b><u>tabulka 10</u></b>	<b><u>Klasifikační funkce plynoucí z analýzy 2</u></b> .....	75
<b><u>tabulka 11</u></b>	<b><u>Klasifikační matice výsledné funkce analýzy 2 – test na sekundárních datech</u></b> . 76	
<b><u>tabulka 12</u></b>	<b><u>Shrnutí proměnných zahrnutých do modelu při analýze 3</u></b> .....	77
<b><u>tabulka 13</u></b>	<b><u>Standardizované koeficienty funkce zvolené na základě Analýzy 3</u></b> .....	78
<b><u>tabulka 14</u></b>	<b><u>Klasifikační matice výsledné funkce analýzy 3 – test na primárních datech</u></b> ....	79
<b><u>tabulka 15</u></b>	<b><u>Parametry klasifikačních funkcí plynoucích z Analýzy 3</u></b> .....	80
<b><u>tabulka 16</u></b>	<b><u>Klasifikační matice výsledné funkce analýzy 3 – test na sekundárních datech</u></b> . 80	
<b><u>tabulka 17</u></b>	<b><u>Přehled výsledků testů klasifikační schopnosti funkcí na primárních datech</u></b> ...	81
<b><u>tabulka 18</u></b>	<b><u>Přehled výsledků testů klasifikační schopnosti funkcí na sekundárních datech</u></b> 82	
<b><u>tabulka 19</u></b>	<b><u>Porovnání výsledků funkcí při aplikaci na data za českou ekonomiku</u></b> .....	85

## 1. STANDARDNÍ NÁSTROJE ŘÍZENÍ ÚVĚROVÉHO RIZIKA

### 1.1. Základní skupiny nástrojů

Podstupování úvěrového rizika je jednou z elementárních funkcí bank, přirozeně vyplývající ze stále dominantního předmětu jejich činnosti. Protože úvěrování vždy patřilo mezi tradiční aktivity banky, má řízení tohoto typu rizika oproti managementu jiných rizik i poměrně dlouhou historii.

V souvislosti se změnami ve struktuře klientů, v poptávce po úvěrových produktech a technologickém vybavení bank doznalo řízení úvěrového rizika během své historie četných změn. Dosud ovšem neexistuje jednotná metoda či koncepce, uznávaná v akademických i ve finančních kruzích. I jednotlivé metody používané v praxi nesou řadu odlišných znaků. Předtím než přistoupím ke zkoumání různých možností měření rizika selhání potenciálního či skutečného klienta, jež představuje ohnisko zájmu této práce, zastavím se krátce u shrnutí základních skupin nástrojů, které má banka k dispozici při snižování rizika plynoucího z půjčování peněžních prostředků.<sup>3</sup>

Např. Heffernan (1996) rozlišuje mezi 4 skupinami nástrojů řízení úvěrového rizika:

- i) ocenění úvěru;<sup>4</sup>
- ii) přidělování úvěrů;<sup>5</sup>
- iii) zajištění zástavou;
- iv) diverzifikace a hedging.

Výše uvedené členění použiji v následujícím textu, jehož cílem je shrnout možnosti, které bankám přinášejí různé nástroje.

#### 1.1.1. Ocenění úvěru

Ocenění úvěru je založeno především na posouzení bonity klienta. Podle výše rizika, přiřazeného každému potenciálnímu klientovi, stanoví pracovníci úvěrového oddělení rizikovou prémii. Ta spolu s výší referenční sazby, danou mezibankovním trhem, a s administrativními náklady banky tvoří základ pro úrokovou míru, nabídnutou konkrétnímu uchazeči.

---

<sup>3</sup> Skupiny nástrojů řízení úvěrového rizika používané komerčními bankami, které popisují v následujících pasážích, jsou pouze jednou stranou mince. V tržních ekonomikách provádí orgány bankovního dohledu *supervizi* nad řízením úvěrového rizika v rámci komerčních bank. Ke kontrole dodržování pravidel obezřetného chování bank mají tyto orgány k dispozici několik měřítek, týkajících se kapitálové přiměřenosti, úvěrové angažovanosti, zásad klasifikace pohledávek apod. Rozbor aktivit bankovního dohledu v tranzitivních ekonomikách včetně ČR nabízí např. Mejstřík, Dvořáková a Neprašová (2001).

<sup>4</sup> „Credit valuation“.

<sup>5</sup> „Credit rationing“.

Nabízí se otázka, zda se banka nemůže zajistit tak, že naučtuje všem klientům preventivně vyšší úrokové sazby, než jaké stanovila na základě odhadu míry jejich rizikovosti, či zda nemá od nákladného systému posuzování bonity upustit a zvýšit plošně rizikovou prémie nad průměr dosahovaný v minulosti. Kýžené výsledky triviálního nadsazení úrovně úrokových sazeb jsou však tlumeny existencí negativního výběru, vyplývajícího z přirozené reakce klientů: Uchazeč o úvěr, který si je vědom vysoké pravděpodobnosti toho, že nebude schopen dostát svým smluvním závazkům vůči bance, přistoupí na poměrně vysokou úrokovou míru častěji než uchazeč s úmyslem jistinu i úroky řádně splatit. Vysoké úrokové sazby mohou tedy zapříčinit zvýšení pravděpodobnosti nesplácení půjček.<sup>6</sup>

### 1.1.2. Selektivní přidělování úvěrů

Pokud pracovníci úvěrového oddělení banky při sestavování balíčku nástrojů řízení úvěrového rizika uvažují existenci negativního výběru, obohatí stanovení požadované výše úrokové sazby o další nástroje. Obvyklým ošetřením problému nepříznivého výběru klientů jsou metody využívané k selektivnímu přidělování úvěrů, spočívající ve vymezení určité skupiny zákazníků, kteří budou mít k danému typu půjčky vyhrazen přístup.

V retailovém bankovníctví, kde se úvěrové oddělení zpravidla zabývá posuzováním mnoha žádostí o půjčku s řádově stejným objemem a s podobným charakterem, je obvyklá kotace velmi úzkého intervalu sazeb pro úvěry. Z něho jsou pak vybírány sazby na konkrétní úvěry, přidělované omezenému počtu jednotlivců či malých firem, splňujících bankou vymezená kritéria. Úvěroví analytici tedy nemají přílišnou vůli ve výběru úrokové sazby, jejich manévrovací prostor je však rozšířen přidáním dalšího nástroje – selekce klientů.

Při úvěrování velkých zavedených firem mají banky přístup k jejich účetním závěrkám schváleným nezávislými auditory. Na základě analýzy finančních výkazů mohou stanovit míru rizikovosti klienta odrážející skutečný stav. Dalším krokem procesu posouzení žádosti o úvěr je rozhodnutí o poskytnutí či odmítnutí půjčky podle toho, zda subjekt dosáhl požadované bonity. Tento krok je obsažen i v postupu přidělování úvěrů malým firmám a jednotlivcům, nastíněném v předchozím odstavci. U velkých firem však banka díky zevrubné analýze výsledků hospodaření firmy může sáhnout po dalším nástroji, a to po stanovení rizikové prémie, a ošetřit tak diametrální rozdíly v rizikovosti jednotlivých klientů. Lze tedy říci, že dva doposud uvedené nástroje – výběr sazby a selekci – lze kombinovat tím lépe, čím detailněji je možné potencionálního klienta a jeho rizikový profil poznat.

---

<sup>6</sup> Problém rostoucí míry úvěrového rizika, způsobený téměř neexistujícím systémem posuzování bonity, můžeme pozorovat na příkladu vývoje českého bankovního sektoru v předchozím desetiletí.

### 1.1.3. Zajištění zástavou

Dalším nástrojem řízení úvěrového rizika je zajištění úvěru pomocí kolaterálu. Skutečnost, že klient poskytne část svých aktiv jako zajištění úvěru, je bezpochyby znamením tendence půjčku splatit. Při zvažování poskytnutí úvěru při dané rizikovosti je však důležité nebrat v úvahu jen okamžitou tržní hodnotu zastaveného aktiva. Významnou roli může totiž sehrát volatilita jeho ceny, podstatně ovlivňující snížení nejistoty splacení. Banky uvažující tento aspekt budou pro dostatečnou kompenzaci rizika ztráty z úvěrového obchodu v případě vysoké volatility ceny zástavy k zajištění obchodu požadovat ceteris paribus větší množství kolaterálu.

### 1.1.4. Diverzifikace a hedging

Mezi základní nástroje snižování celkové míry rizikovosti portfolia úvěrů nepochybně patří jeho diverzifikace. Pokud má banka možnost poskytovat půjčky, jejichž výnosy jsou negativně korelovány, může diverzifikací mezi tyto typy úvěrů zamezit veškerému nesystémovému riziku a minimalizovat tak své ztráty plynoucí z nesplácení. K jejímu dosažení je používána korelační analýza, zaměřená na pozorování závislostí mezi pohyby proměnných na trhu. Jednoduchým nástrojem kontroly diverzifikace portfolia je stanovení limitů úvěrové angažovanosti v jednotlivých sektorech, oblastech podnikání, regionech, apod. Omezenou možnost poskytování půjček se vzájemně negativně korelovanými výnosy je dále možné řešit použitím vhodných zajišťovacích nástrojů.

## 1.2. Odhady platební disciplíny jako předpoklad úspěšného úvěrování

Jak jsem nastínila výše, rozhodla jsem se v rámci této práce zaměřit především na metody posouzení míry rizika, kterou přináší každý potenciální či stávající klient. V logice členění nástrojů řízení úvěrového rizika do skupin, navržené Heffernanem,<sup>7</sup> lze tyto metody zařadit především do skupiny ocenění úvěru. Na správném ohodnocení rizikovosti klienta však dle mého názoru závisí i úspěšnost použití všech ostatních nástrojů managementu úvěrování. Je na něm založeno rozhodování o přidělení či zamítnutí úvěru, o adekvátnosti nabídnutého kolaterálu i o míře a způsobu zajištění. Zvládnutí nástrojů odhadu bonity klienta lze tedy nahlížet jako primární předpoklad úspěšného úvěrování.

### 1.2.1. Přístupy k ohodnocení bonity klienta

Předtím než přistoupím k deskripci postupů používaných v oblasti odhadu bonity potenciálních klientů a k analýze možností jejich vylepšení, ráda bych se soustředila na nastínění různých pojetí této činnosti. Jednou z možných cest rozlišení mezi různými přístupy k hodnocení rizikovosti klienta je použití historického hlediska. Podle Andertona (1995) je z tohoto hlediska možné

rozlišovat mezi tradičním a novým přístupem k posuzování bonity klientů,<sup>8</sup> které se podstatně liší používanými metodami.

### 1.2.1.1. Tradiční přístup

Tradiční přístup k rozhodování o poskytování úvěrů je založen na odborném posouzení úvěrového návrhu pracovníkem banky a na jeho ohodnocení z několika předem stanovených hledisek. Může se jednat o více či méně standardizovaný postup, na jehož základě úvěrový expert provádí analýzu vhodnosti poskytnutí úvěru.<sup>9</sup>

Altman, Caouette a Narayanan (1998) upozorňují na výsledky svých výzkumných prací, které poukazují na podstatné pozitivní dopady použití cenných zkušeností úvěrového odborníka na kvalitu úvěrových rozhodnutí:

- Úvěrový expert může nové případy posuzovat s ohledem na vlastní zkušenosti z předchozí praxe a je pro jiné pracovníky zdrojem informací o předchozích rozhodnutích, formujících kulturu banky.
- Pracovníci úvěrového oddělení s bohatými zkušenostmi jsou schopni provést četné odhady „od oka“,<sup>10</sup> které jsou rychlým ověřením ostatních typů analýz. Odhady „od oka“ jsou důležité zvláště při ohodnocování dopadů nečíselných proměnných na odhad rizikovitosti subjektu. Jsou velmi důležité i pro posuzování rozdílných výsledků dosažených při použití více analytických metod.
- Banky se na zkušené úvěrové odborníky mohou často spolehnout ve vytipování otázek týkajících se subjektu, které jsou pro rozhodnutí o úvěru nejdůležitější.<sup>11</sup>

Bez odborného posouzení úvěrového návrhu expertem je přirozeně prakticky nemožné provádět správná rozhodnutí o půjčkách. Jsem však toho názoru, že spoléhání se výhradně na úsudky jednotlivých odborníků v sobě skrývá kromě přínosu k profesionalitě analýzy i několik nevýhod.

---

<sup>7</sup> Heffernan (1996) – viz výše.

<sup>8</sup> Vymezení přístupů pomocí doby prosazování metod používaných v jejich rámci může působit poněkud vágně. Za výstižnější považuji diferenciaci postupů pomocí sledování, do jaké míry jejich metody inklinují k individuálnímu posuzování každého subjektu (tradiční přístup), respektive ke sledování struktury celé populace (nový přístup) – viz níže.

<sup>9</sup> Některé banky pro zjednodušení posuzování žádostí vyvinuly různé mnemotechnické pomůcky, shrnující první písmena hledisek posuzování úvěrového návrhu do jednoho slova. Např. CAMPARI (Character, Ability, Means, Purpose, Amount, Repayment, Insurance) používané Barclays Bank.

<sup>10</sup> V literatuře se často setkáváme s výrazem „rule of thumb“.

<sup>11</sup> Mezi takové otázky patří například vytipování rozhodujících trendů v odvětví apod.

Na výsledky analýzy má totiž nepochybně dopad přirozená přítomnost lidského faktoru v rozhodování. Každý z odborníků je jedinečnou osobností, vnášející do posuzování návrhů subjektivní elementy. Je velmi pravděpodobné, že při předložení úvěrového návrhu vysoce bonitního klienta více odborníkům obdržíme od všech shodný výsledek v podobě doporučení poskytnutí úvěru. Pokud naopak skupině odborníků předložíme k samostatnému posouzení a priori naprosto neakceptovatelné žádosti, dostaneme bezpochyby od všech odpověď zamítavou. V bankovní praxi spadá však většina posuzovaných návrhů do pásma mezi těmito krajními eventualitami. Vlastnosti konkrétní osoby, posuzující návrh, proto hrají důležitou roli. Osud úvěrového návrhu může být do určité míry závislý na výběru pracovníka, kterému bude posouzení svěřeno, či na jeho momentální náladě – faktorech značně náhodných.

Právě popsané důsledky subjektivity lidského rozhodování mají nepochybně dopad na srovnatelnost úsudků manažerů v rámci pobočky či banky. Nekonzistentnost v úsudcích jednotlivých pracovníků a nesrovnatelnost závěrů různých odborníků jsou faktory, které vedení banky ochuzují nejen o měřítko kvality jednotlivých úvěrových obchodů a možnost ohodnocení rizikové struktury úvěrového portfolia, ale i o účinný nástroj centrálního ovlivňování úvěrové činnosti. Při posuzování portfolia úvěrových obchodů uzavřených různými odborníky musí vedení brát v úvahu, že má před sebou skupiny úvěrů, v jejichž rámci jsou kontrakty sice charakterizovány stejnými či podobnými smluvními podmínkami, které však vykazují naprosto odlišné míry rizika.

Altman, Caouette a Narayanan (1998) diskutují zajímavý aspekt vlivu lidského faktoru na kvalitu rozhodování v souvislosti s rostoucí koncentrací bankovníctví. V dobách, kdy měl ve věci poskytování veškerých půjček rozhodující slovo jeden člen vedení banky, byla konzistentnost rozhodování na bázi tradičního přístupu dosažitelná. V současné době se však stavy zaměstnanců bank počítají v desetitisících a počet pracovníků provádějících úvěrová rozhodnutí je tak mnohem vyšší. V důsledku toho, že koncentrace odvětví bankovníctví je nejčastěji zvyšována fúzemí, sledují pracovníci jedné banky, kteří prošli různými školicími programy, často zcela jiná měřítka rizikovitosti. Splynutí dvou či více bankovních subjektů je tedy v zájmu konzistentnosti nutně provázeno restrukturalizací používaných procesů. Pokud je však nově vytvořený systém posuzování úvěrových návrhů, vycházející z kompromisu mezi několika původními systémy, příliš komplexní, může v extrémním případě náklad času stráveného nad jeho studiem přesáhnout výnosy, plynoucí z jeho používání.

Další paradox nastává v případě, že je tvorba nových směrnic úvěrování po fúzi příliš poznamenána obavami z důsledků existence rozdílného zázemí, kultury a vyškolení pracovníků. Výsledná kritéria hodnocení bonity mohou být v takové situaci příliš náročná a mohou vést k podstatnému snížení celkové míry rizika portfolia banky. Protože nízké riziko je spojeno s nízkou mírou kompenzace, může být důsledkem přílišné opatrnosti pokles ziskovosti obchodů.

S přítomností lidského faktoru v rozhodování souvisí také vznik dodatečných nákladů, které jsou vyvolány opakováním některých analytických procesů. Altman, Caouette a Narayanan (1998)



uvádějí, že nejčastěji lze paralelnost procesů posuzování bonity klienta pozorovat v případě syndikátní půjčky. Důvodem jsou nejen tendence bank ke vzájemné nedůvěře v profesionalitu interních expertů, ale i právní aspekty vztahu bank sjednávajících společně poskytnutí půjčky. Důsledkem těchto preventivních opatření mohou být vážné problémy s neefektivností a náklady.

Překrývání shodných procesů se podle mého názoru může objevit i v rámci jednotlivých bank. Ústředí banky může mít totiž z důvodů znalosti různých vychýlení rozhodování u jednotlivých poboček, jejichž vznik jsem popsala výše, motivaci znovu podniknout analýzu provedenou již na pobočce.

Nepříznivé vlivy lidského faktoru přítomného v rozhodování o úvěrech jsou, jak je vidět, vzájemně velmi propojené. Domnívám se, že ztlumení jejich vlivu na efektivitu rozhodovacích procesů je silným podnětem pro přehodnocení tradičního přístupu k úvěrování.

#### 1.2.1.2. Nový přístup

Zejména identifikace nastíněných nevýhod tradičního přístupu vede ke stále silnějšímu prosazování nového přístupu k ohodnocování úvěrových návrhů a k zapojování jeho postupů do praxe managementu úvěrování. Nový přístup k managementu úvěrování, který se nepochybně rozvíjí hlavně díky rychlému pokroku v oblasti informačních technologií, je orientován zejména na zodpovídání komplexních otázek, které mají tendenci vyskytovat se opakovaně. V oblasti úvěrování jde o spotřebitelské úvěry se standardním objemem, žádosti o kreditní karty, půjčky podnikatelům s obdobným předmětem činnosti apod. Nový přístup je založen na systému postupů, který vychází ze zjištění závislosti bonity klienta na skupině nezávisle proměnných. Výstupem metod nového přístupu je odpověď na klíčovou otázku, zda posuzovaný subjekt bude schopen plnit závazky plynoucí z úvěrové smlouvy.<sup>12</sup>

Pro účely posouzení bonity klientů jsou v bankovníctví používány především modely posuzování firem, založené na následujících metodách:

- klasická statistika;
- umělá inteligence;
- expertní systémy.

V následující pasáži se pokusím shrnout nejvýznamnější přednosti i nedostatky uvedených metod.

---

<sup>12</sup> Odpověď na tuto otázku je klíčová nejen při zvažování vstupu do věřitelské pozice vůči posuzovanému subjektu, ale i při odhadování míry rizika celého portfolia banky.

#### 1.2.1.2.1. Výhody a nevýhody jednotlivých metod nového přístupu

Nespornou výhodou využití všech výše uvedených typů systémů je možnost posouzení žadatele o úvěr na základě více hledisek s ohledem na interakci mezi jednotlivými parametry.<sup>13</sup>

Protože jsou uvedené metody koncepčně odlišné, liší se do určité míry postup i výsledek jejich použití. Na některé odlišnosti, zřejmě i bez srovnávací studie výsledků jednotlivých metod, bych ráda upozornila v následujících odstavcích.

První dvě skupiny postupů – klasická statistika a umělá inteligence – mohou poukázat na důležité závislosti, jejichž významnost by bez aplikace těchto metod zůstala neznámou. Použití metod klasické statistiky či umělé inteligence je tedy výhodné zařadit na počátek analýzy. Výsledky pak mohou sloužit jako dílčí vstupy, které je nutné interpretovat a zpracovat pro vyslovení závěru o finančním zdraví firmy. Expertní systémy naopak staví na zapracování zkušeností z mnoha analýz, které odborník provedl v minulosti. Použití expertního systému je z tohoto důvodu vhodné až po vytipování proměnných, důležitých pro nadcházející stav firmy.

Oba typy systémů představují nepochybně přínos ve směru objektivnosti a efektivity rozhodování o úvěrech. Rozsah snížení nepříznivého vlivu lidského faktoru na rozhodování, který použití těchto metod může generovat, je však podle mého názoru u jednotlivých metod odlišný: Expertní systém ve své původní podobě představuje soubor pravidel, sestavený na základě zkušeností odborníků z poskytování úvěrů. Nejčastěji má tento systém podobu tzv. rozhodovacího stromu. Jednotlivé žádosti o úvěr probíhají na základě hodnot různých kritérií, vyapovídajících o míře splnění požadavku, strukturou rozhodovacího stromu. Výstupem expertního systému v původní podobě je odpověď, jakou by přineslo posouzení žádosti samotným autorem expertního systému.<sup>14</sup> Využití takového systému pak může přinést zvýšení míry objektivnosti rozhodování v rámci banky. Jedná se o řešení výše popsaného problému nesrovnatelnosti úsudků manažerů jednotlivých poboček.

Domnívám se, že statistika a neuronové sítě nabízejí zvýšení objektivity posuzování žádostí v mnohem širším smyslu. Na rozdíl od expertních systémů totiž nestaví na pravidlech, ale na případech.<sup>15</sup> Jsou zaměřeny na modelování struktury souborů pozorování. To jim umožňuje vyřadit lidský faktor, a snížit tak riziko zaměření se na vztahy a parametry, které mají z hlediska celé skupiny žadatelů malý význam.<sup>16</sup>

---

<sup>13</sup> Anglicky psaná literatura – např. Altman (1968) – tuto vlastnost shrnuje v termínu „multidimensionality of analysis“.

<sup>14</sup> Jednou z modifikací původní podoby expertních systémů, na které se uvedená úvaha nevztahuje, jsou tzv. regresní stromy – viz pozn. 16.

<sup>15</sup> Anglicky psaná literatura zabývající se klasifikací klientů pro expertní systémy často používá termínu „rules-based techniques“, pro statistické metody a metody neuronových sítí pak pojmu „case-based techniques“. Tyto termíny podle mého názoru nejlépe vystihují v textu nastíněný rozdíl mezi metodami.

<sup>16</sup> V této souvislosti zmíním další skupinu modelů, čerpající jak z expertních systémů, tak z metod klasické statistiky. Jedná se o tzv. regresní stromy. Na základě statistických šetření získané znalosti o struktuře populace jsou systematicky utříděny do struktury rozhodovacího stromu, jehož funkce je stejná jako u expertních systémů. Tyto systémy jsou spojením výhod obou typů modelů, a představují tak ucelený systém identifikace klíčových

Při výběru metody, která bude použita pro posuzování bonity klientů, je nepochybně důležité zkoumat rovněž schopnost adaptability metod na nové podmínky. Finanční zdraví podniků je totiž závislé na velkém množství parametrů, jejichž vztahy se mohou rychle měnit. Z výše popsané možnosti využití statistických metod a modelů založených na neuronových sítích k rozpoznávání důležitých vztahů mezi daty přirozeně plyne jejich schopnost přizpůsobit se změnám ve struktuře klientů a nákladů banky. Při použití expertních systémů vyžaduje naproti tomu změna struktury dat přepracování hierarchie pravidel modelu. Vytvoření funkčního expertního systému proto závisí na dokonalé znalosti okamžitých vztahů mezi pozorovanými charakteristikami klientů. Udržení funkčnosti se neobejde bez neustálého sledování změn vztahů, průběžné korekce systému a mnohdy i přepracování celé struktury pravidel.

Ve výběru nástroje systemizace řízení úvěrového rizika je vedle posouzení flexibility a dosažitelné míry objektivity vhodné zohlednit také možnost využití výsledků daného postupu v dalších analýzách prováděných potenciálním věřitelem. Skutečnost, že výsledky dosažené pomocí neuronových sítí zatím není možné shrnout pomocí matematického vyjádření funkční závislosti, dle mého značně omezuje možnost interpretace jejich výstupu a použití poznatků v dalších analýzách.

### **1.3. Závěr**

V úvodu k první Kapitole jsem se pokusila shrnout základní nástroje, která má banka k dispozici k tomu, aby měřila a snižovala míru rizika plynoucí z úvěrování. V další části této kapitoly jsem se soustředila na zkoumání různých přístupů k měření rizikovitosti jednotlivých klientů, jehož zvládnutí považuji za primární předpoklad úspěchu úvěrování. Pokusila jsem se nastínit nejvýznamnější rozdíly mezi různými metodami tzv. nového přístupu k posuzování bonity a na obecné rovině srovnat možnosti, které tyto metody přinášejí. Zhodnocení výhod a nevýhod jednotlivých typů modelů, které jsem uvedla, může být výchozím bodem pro srovnávací studii výsledků aplikace zmíněných metod v praxi. Pro mne byly výše uvedené úvahy podkladem pro posouzení, jak si ve srovnání metod z uvedených hledisek vede metoda diskriminační analýzy, jejíž výkonnost budu testovat v rámci této práce.

Před vyložení základních rysů modelu diskriminační analýzy a rozborem možností jeho použití pro posuzování nadcházející finanční situace subjektů na teoretické a praktické rovině se v rámci druhé kapitoly zaměřím na zhodnocení potenciálu, který aplikace metod nového přístupu může přinést českému bankovníctví.

---

závislostí a aplikace těchto poznatků přímo na rozhodování. Vhodnost regresních stromů pro české prostředí je dle mého názoru zajímavým námětem případné další studie možností systemizace managementu úvěrování.

## 2. SITUACE V ČESKÉM BANKOVNICTVÍ

Jak jsem již uvedla, je cílem této práce prozkoumat možnosti využití metod klasické statistiky k systemizaci postupů používaných pro řízení úvěrového rizika. Jednou z klíčových motivací pro volbu tohoto tématu byl vývoj, jakým prošel český bankovní sektor na sklonku tisíciletí.

Abych připomněla rozsah problémů, jakým může být bankovní sektor vystaven, pokud koncepční metoda řízení úvěrového rizika neexistuje, shrnu v následující pasáži procesy, kterými v uplynulém desetiletí český bankovní sektor prošel. V další části této kapitoly se zamyslím nad tím, jakou roli v oboru měření a řízení úvěrového rizika v českém bankovníctví hrají, respektive mohou hrát, metody klasické statistiky.

### 2.1. Programy konsolidace – řešení ex post

Přestože došlo ke vzniku komerčních bank v České republice v době, kdy bankovníctví ve vyspělých zemích prodělávalo fázi deregulace a s ní spojené důležité inovace, netěšil se vývoj českého bankovního sektoru z externalit těchto procesů. Prosazující se mezinárodní standardy řízení rizik vznikající na základě dlouholetých zkušeností finančníků vyspělých zemí bohužel neovlivnily české bankovníctví v devadesátých letech do takové míry, aby zamezily vzniku problémů, typických pro transformující se ekonomiky.

Pokusím se nyní shrnout aspekty živelného vývoje českého komerčního bankovníctví týkající se úvěrového rizika.<sup>17</sup> Vznik tisíců nových podnikatelských subjektů přinesl prudký nárůst poptávky po bankovních službách. Docházelo k masovému zřizování účtů, nárůstu platebního styku, ale i ke zvyšování poptávky po úvěrech. Reakcí byl na jedné straně rozvoj obchodní sítě a produktů existujících bank, na straně druhé pak zájem nově vzniklých subjektů o vstup na tento trh. Zahraniční banky přistupovaly k nestandardnímu prostředí velmi obezřetně,<sup>18</sup> prudký růst sektoru se proto vydal především cestou vzniku nových bank s českým kapitálem.

Poptávka po bankovních službách se při neexistenci kapitálového trhu stále více orientovala na úvěrové obchody. Tlak na banky rostl s rostoucím objemem potřeb financování vznikajících v rámci privatizačního procesu. Vzhledem k nedostatku zkušeností pracovníků bank s poskytováním úvěrů a s používáním systémů posuzování bonity nebyla rozhodnutí prováděna na profesionálním základě. K nárůstu problému dále přispěl nedostatek informací o nových podnicích a nízká vypovídací schopnost stávajících údajů. To se projevilo především ve zvýšeném podílu chybných rozhodnutí

---

<sup>17</sup> Podrobnější popis vývoje českého komerčního bankovníctví nabízí např. Mejstřík, Dvořáková a Neprašová (2001). Je ho možné nalézt i ve Zprávě o činnosti bankovního dohledu v ČR (1999).

<sup>18</sup> I v období, kdy zahraniční banky začaly na český trh vstupovat, zaměřily své aktivity na vybraný okruh vysoce bonitních klientů.

o úvěrech a o velikosti vytvářených kapitálových polštářů. Vznikl však zároveň prostor pro úvěrové podvody, půjčování spřízněným stranám a další formy morálního hazardu.

V důsledku těchto vlivů se hromadily klasifikované úvěry. Nedostatek kapitálu ke krytí ztrátových úvěrů byl jedním z hlavních motivů velmi nákladných programů restrukturalizace českého bankovního sektoru. Abych připomněla rozsah opatření, vynucených rozsahem a závažností popsaných problémů, v kostce shrnu základní pilíře konsolidace českého bankovníctví.<sup>19</sup>

### 2.1.1. Konsolidační program I

Konsolidační program I byl zaměřen na záchranu státních bank,<sup>20</sup> jejichž úvěrová portfolia byla zatížena velkými objemy úvěrů z minulosti. V rámci tohoto programu byly provedeny operace zaměřené na čištění bilancí bank a jejich kapitálové posilování. Celkové náklady programu jsou odhadovány na 101,6 miliardy Kč.<sup>21</sup>

### 2.1.2. Konsolidační program II

Konsolidační program II, zahájený v roce 1996, byl vyvolán zejména nekvalitní strukturou úvěrových portfolií malých bank.<sup>22</sup> Mezi hlavní nástroje zaměřené na snížení rizika, kterému byly banky vystaveny špatným managementem úvěrování a nízkou kapitálovou přiměřeností, patřilo navyšování kapitálu, zavádění nucených správ, podpora prodeje novým investorům, odebírání licencí, apod. S cílem předejít systémové krizi garantovala ČNB výplatu vkladů nad rámec Fondu pojištění vkladů do výše 4 mil. Kč.<sup>23</sup> Výplaty náhrad vkladů do této výše uspokojily více než 99 % počtu klientů bank; z hlediska objemu ovšem pokrývaly pouze 66 % celkové hodnoty vkladů.<sup>24</sup> Hrubá výše prostředků vydaných ČNB v rámci Konsolidačního programu II činila 32,9 miliardy Kč.<sup>25</sup>

Mimo rámec programu konsolidace malých bank, avšak ve stejné době, byla řešena situace v Agrobance Praha, a. s. Protože šlo o největší soukromou banku působící v ČR, byla možnost jejího úpadku vnímána jako hrozba znehodnocení všech zásahů v subsektoru soukromých bank. S cílem zajištění stability bankovního sektoru se proto ČNB rozhodla udržet banku v plném provozu i během nucené správy a důvěru klientů dále posílit vydáním záruky za jejich vklady. Agrobanka, která až do roku 1995 spolupracovala s bankovním dohledem na programu zaměřeném na zlepšení situace, však po převzetí novým vlastníkem změnila postoj. Přestala plnit sjednané kroky, prováděla rizikové obchody, které vedly především ke zhoršení kvality úvěrového portfolia. Dostala se tak do tristní

---

<sup>19</sup> Důkladný rozbor jednotlivých fází transformace českého bankovního sektoru a diskusi dopadu státních intervencí nabízí např. Mejstřík, Dvořáková a Neprašová (2001).

<sup>20</sup> Komerční banky, České spořitelny, Investiční banky a Státní banky československé

<sup>21</sup> Výpočet ČNB provedený na základě údajů k 31. 8. 1999.

<sup>22</sup> Vznik nekvalitních úvěrových vztahů byl spjat zejména s prudkým nárůstem poptávky po financování v souvislosti s privatizačním procesem (za neexistence jiných zdrojů) a s nedostatkem informací o žadatelích – viz výše.

<sup>23</sup> Výplaty v rámci pojištění vkladů představovaly v té době maximálně 100 000 Kč.

<sup>24</sup> Zdroj: ČNB (1999).

likvidní situace, která vyústila v uvalení nucené správy. Situaci řešila ČNB podporou vstupu strategického investora<sup>26</sup> v podobě kompenzace ztrát z převzetí části podniku se zápornou hodnotou. Kromě toho se ČNB podílela na navýšení základního jmění banky a poskytla překlenovací úvěry.

V souvislosti s Konsolidačním programem II, s řešením situace Agrobanky a situací Kreditní a průmyslové banky, AB banky a Banky Bohemia<sup>27</sup> byly vynaloženy ČNB a ze státního rozpočtu<sup>28</sup> náklady, jejichž agregovaná úroveň je odhadována na 105,5 miliardy Kč.<sup>29</sup>

### 2.1.3. Stabilizační program

Změny struktury odvětví malých bank vyvolané Konsolidačním programem II. hrozily dalším nebezpečím, plynoucím ze ztráty důvěry v tyto banky, a to nebezpečím likviditních problémů. Řešení této hrozby bylo shrnuto ve Stabilizačním programu vydaného vládou na podzim roku 1996. Program spočíval v odkupu nekvalitních pohledávek bank Českou finanční (ČF) a garancí zpětné kompenzace, kterou by banky poskytly ČF za pohledávky, nerealizované během programu, tedy během 7 let. Banky, které se od roku 1997 začaly programu účastnit, musely splňovat kritéria předepsaná v rámci programu.<sup>30</sup> V důsledku jejich neplnění ČNB ukončila účast v programu a odebrala licenci 3 bankám,<sup>31</sup> u 2 bank byla účast na programu ukončena splacením závazků České finanční novým majitelem.<sup>32</sup> Jedinou banku, která program dokončila, byla v roce 2000 eBanka.

### 2.1.4. Čištění portfolií bank před jejich privatizací

Další fází restrukturalizace bankovního sektoru bylo dokončení privatizace velkých státních bank. V červnu roku 1999 byla prodejem podílů ČNB (34 %) a NBS (17 %) belgické bance KBC za více než 1 miliardu Euro zprivatizována ČSOB, tedy banka, jejíž portfolio vykazovalo nejméně problémů. Řešení situace ostatních velkých bank však na rozdíl od případu ČSOB generovalo další výdaje ze státního rozpočtu. V roce 2000 musel být nucenou správou a následným rychlým přesunem IPB pod ČSOB dodatečně řešen předchozí prodej banky IPB skupině Nomura.<sup>33</sup>

Další náklady pak přineslo očištění úvěrového portfolia vyvedením ztrátových úvěrů v případě ČS (v roce 2000) a KB (v roce 2001) před jejich prodejem strategickým partnerům.<sup>34</sup>

---

<sup>25</sup> Bez zohlednění splátek a jiných výnosů.

<sup>26</sup> Společnosti GE.

<sup>27</sup> Situace těchto tří bank byla řešena ještě před zahájením Konsolidačního programu II.

<sup>28</sup> Např. plnění ze státní záruky vůči České spořitelně na základě Usnesení vlády č. 370/1998. Záruka byla vydána v souvislosti s řešením situace AB banky.

<sup>29</sup> Výpočet ČNB na základě údajů k 31. 12. 1999.

<sup>30</sup> Podmínkou nutnou k setrvání v programu bylo vedle plnění limitů rizika a nákladů také vytváření rezerv pro kompenzaci ČF ve výši 1/7 celkového objemu odkoupených pohledávek.

<sup>31</sup> Pragobance a Universal bance v roce 1998, Moravia Bance v roce 1999.

<sup>32</sup> Banka Haná (závazek k ČF převzala IPB), Foresbank (závazek ČF splatila Union Banka).

<sup>33</sup> Ten byl vyvolaný ztrátou státní majority v roce 1998 při navyšování kapitálu

<sup>34</sup> Očištěnou Českou spořitelnu koupila Erste Bank Sparkassen za 19,4 miliardy Kč, Komerční banka byla firmě Societ e G n rale prodána za 40,2 miliardy Kč. Po očištění těchto příjmů státního rozpočtu o výdaje spojené s restrukturalizací je však odhadován negativní v sledek operací.

Opatření, shrnutá v předchozích odstavcích, byla ze společenského hlediska a vzhledem k jejich účinku velmi nákladnou formou řešení problémů bankovního sektoru. Problémem, který bývá označován za hlavní impuls popsaných kroků, je zvýšená míra úvěrového rizika reprezentovaná vysokým poměrem klasifikovaných úvěrů nekrytých dostatečnými kapitálovými polštáři. V rámci této práce se pokusím přispět k nalezení odpovědi na otázku, jak je možné problémům s úvěrovým rizikem předcházet, a vyhýbat se tak jejich nákladnému a ne vždy účinnému řešení ex post. V následující pasáži proto shrnu možnosti, po kterých české banky při hledání systému posuzování bonity klientů mohou sáhnout.

## 2.2. Prostor pro řešení ex ante

Po restrukturalizaci, popsané v podkapitole 2.1, je tuzemský sektor komerčního bankovníctví téměř výhradně v rukou zahraničních investorů. V této situaci se pro český bankovní sektor stává aktuálním i nový směr regulace měření a řízení úvěrového rizika, navržený Novou basilejskou dohodou o kapitálové přiměřenosti. V následující podkapitole shrnu rysy navrhovaných změn, významné z hlediska této práce. Poté se zaměřím na zhodnocení možností, které před sebou v tomto kontextu mají tuzemské komerční banky při výběru vhodné metody měření úvěrového rizika.

### 2.2.1. Nová basilejská dohoda a interní modely řízení úvěrového rizika

Nová basilejská dohoda o kapitálové přiměřenosti<sup>35</sup> je zaměřena na aktualizaci metod výpočtů kapitálových požadavků týkajících se velkých mezinárodně orientovaných bank. Cílem publikování tohoto dokumentu bylo zejména vyvolání diskuse možností zobrazení posledního vývoje ve finančním sektoru do změn starých směrnic zahrnutých v Basilejské dohodě z roku 1988.

Nová basilejská dohoda neruší standardní a doposud používaný způsob výpočtu kapitálové přiměřenosti.<sup>36</sup> Jejím cílem je obohatit škálu nástrojů regulátora o pokročilé a flexibilnější metody stanovení požadavku na kapitál. Zásadním krokem vpřed, který Nová basilejská dohoda navrhuje, je podle Karacadaga a Taylora<sup>37</sup> přechod od metod založených na pravidlech na metody zaměřené na flexibilnější, procesně orientovaný přístup.<sup>38</sup> Jedním z rozměrů tohoto posunu je například návrh, aby banky mohly k měření kvality pohledávek používat úvěrová hodnocení publikovaná externími

---

<sup>35</sup> Návrh dohody byl vydán v roce 1999 jako konzultativní materiál a byl předmětem diskuse o vhodnosti jednotlivých navrhovaných úprav, jíž se účastnila i ČNB. Další konzultativní návrh vydal Basilejský výbor v lednu 2001. Ten byl podkladem pro diskusi do května 2001. Obsahuje vymezení oblastí změn v regulaci kapitálu s ohledem na současný stav měření úvěrového rizika a Basilejský výbor očekává, že začnou subjekty bankovního dohledu aplikovat rámec navržený Novou basilejskou dohodou především pro mezinárodně orientované komerční banky v roce 2004. Úplné znění dohody je k dispozici na [www.bis.org](http://www.bis.org).

<sup>36</sup> Pro způsob výpočtu kapitálové přiměřenosti českých bank viz Opatření ČNB č. 3 ze dne 28. června 1999 – O kapitálové přiměřenosti bank zahrnující úvěrové a tržní riziko.

<sup>37</sup> Karacadag, Taylor (2000) cit. Derviz, Kadlčáková (2001).

<sup>38</sup> Tato změna postoje BIS byla vyvolána zejména kritikou přílišné mechaničnosti výpočtu kapitálových požadavků nezobrazující změny v současném finančnictví. Viz Derviz, Kadlčáková (2001).

ratingovými firmami.<sup>39</sup> Podle starých směrnic je např. pohledávkám za nefinančními entitami přiřazena riziková váha 100 %. Podle nového přístupu by tyto pohledávky, pokud by příslušely do bezrizikové země a externí firma by jim přiřadila vysoký rating, mohly mít nižší váhu.

Další dimenzí změny je skutečnost, že banky budou moci v blízké budoucnosti ke stanovení úrovně regulovaného kapitálu využívat vlastních modelů měření rizika,<sup>40</sup> po případě modelů vytvářených jinými společnostmi aktivními ve finančním sektoru.<sup>41</sup>

Derviz a Kadlčáková (2001) zdůrazňují, že jedním z možných důsledků implementace přístupu navrženého v Nové basilejské dohodě je postupné snižování, respektive zánik rozdílu mezi kapitálovým požadavkem regulátora a úrovní kapitálu rovnovážnou z hlediska bank.<sup>42</sup> Úroveň rovnovážná z hlediska banky zachycuje odhad objemu kapitálu, který by měl být držen pro krytí neočekávaných ztrát. Naproti tomu regulatorní kapitálový požadavek představuje opatření považované regulátorem za přiměřené tomu, aby byla zachována stabilita a spolehlivost bankovního systému jako celku. Vytvoření prostoru pro stírání rozdílu mezi těmito dvěma úrovněmi je podmíněno splněním implicitního předpokladu, že odhady vytvářené pomocí interních modelů měření úvěrového rizika jsou dostatečně spolehlivé, aby kromě efektivity managementu úvěrování zajistily i stabilitu celého systému.

V následujících pasážích se zabývám dosažitelností těchto požadavků pomocí dvou typů modelů – modelů vytvořených renomovanými finančními institucemi na základě analýzy změn ratingového hodnocení jednotlivých subjektů na straně jedné<sup>43</sup> a vlastních modelů komerčních bank na straně druhé.

### 2.2.2. Modely založené na ratingu

Jak jsem zmínila výše, zakládá se přístup k regulaci navržený Novou basilejskou dohodou na efektivnosti interních modelů z hlediska jednotlivých bank a zároveň na jejich spolehlivosti z hlediska stability bankovního sektoru. Výběr vhodného způsobu měření úvěrového rizika je z tohoto důvodu věcí posouzení obou aspektů a spolupráce centrálních bank s bankami komerčními.

Převzetí modelů měření úvěrového rizika, konstruovaných renomovanými firmami na základě dlouholetých zkušeností z finančního sektoru,<sup>44</sup> může tuzemským komerčním bankám přinést

<sup>39</sup> Např. ratingy Moody's Standard & Poor's.

<sup>40</sup> Modely jsou v anglicky psané literatuře nazývány „internal rating models (IRM)“. V češtině je proto někdy používán též výraz „interní modely“.

<sup>41</sup> Tzv. „industry-sponsored models“, tedy modelů vytvořených špičkovými experty odvětví a přejímaných ostatními finančními institucemi.

<sup>42</sup> V anglické literatuře „regulatory vs economic capital“.

<sup>43</sup> „Industry-sponsored models“ – viz pozn. 41.

<sup>44</sup> Nejznámějšími příklady interních modelů rozšiřovaných na celé odvětví jsou postupy měření úvěrového rizika, které v druhé polovině devadesátých let začaly zveřejňovat zavedené finanční instituce JP Morgan, Credit Suisse, KMV Corporation a McKinsey. Citovaná studie Dervize a Kadlčákové (2001) obsahuje popis přístupů k měření úvěrového rizika pomocí modelů těchto společností. Zároveň se v rámci této studie, která podle mého názoru představuje klíčový materiál pro rozhodování o vhodnosti jednotlivých metod pro různá prostředí, její autoři zamýšlejí nad výhodami i nevýhodami aplikace každého z modelů v ČR.



především zvýšení objektivit, srovnatelnosti mezi pobočkami apod. Centrální bance může použití vhodně zvoleného modelu v komerčních bankách pomoci zvýšit transparentnost úvěrování a zkvalitnit kontrolu vhodnosti regulace, po případě být přímo jejím nástrojem.<sup>45</sup>

Vedle přínosů oběma stranám však existují i nepřehlédnutelné překážky implementace modelů renomovaných finančních institucí, pocíťované v krátkém období zejména komerčními bankami. Jednou z hlavních komplikací implementace modelů typu „industry-sponsored“ je neexistence potřebných dat. Použití drtivé většiny modelů tohoto typu je totiž podmíněno existencí ratingového hodnocení posuzovaného klienta. Pro konstrukci matic propustnosti<sup>46</sup> či proměnných zachycujících specifika země a odvětví jsou navíc potřebné dostatečně dlouhé časové řady pohybu pozorování z jedné ratingové třídy do jiné.<sup>47</sup> Možnost adaptace těchto modelů pro prostředí, ve kterém chybí nejen tyto časové řady, ale i rating velkého procenta firem,<sup>48</sup> je tedy limitována.

Další možnou překážkou implementace diskutovaných modelů z hlediska komerčních bank je poměrně komplexní povaha všech modelů a souvisejících odhadových metod, vyžadující využití pokročilého programového vybavení. Zavedení těchto modelů je tedy podmíněno ochotou bank investovat do know-how, školení pracovníků a v neposlední řadě do nákupu nového softwarového vybavení.

### 2.2.3. Interní modely tuzemských komerčních bank

Ve světle časové a finanční náročnosti překonání výše uvedených překážek se Derviz a Kadlčáková (2001) zamýšlejí nad alternativními modely posuzování úvěrového rizika, vytvářenými tuzemskými bankami. Autoři citované studie zdůrazňují zejména přínosy metod založených na statistické analýze. Vedle nižší náročnosti na data<sup>49</sup> je jejich předností zejména schopnost zachytit charakteristické rysy českého prostředí. Derviz a Kadlčáková zmiňují i možnost nabytí znalostí a dovedností nutných k adaptaci a využití složitějších modelů renomovaných finančních skupin.

V následující pasáži se budu zabývat podmínkami, které pro tvorbu vlastních modelů bonity vyplývají ze současné situace v České republice.

---

<sup>45</sup> Různé možnosti regulace (standardní přístup, respektive přístup založený na měření rizika pomocí flexibilních modelů) jsou podrobně popsány v návrhu Nové basilejské dohody, dostupném na internetových stránkách [www.bis.org](http://www.bis.org).

<sup>46</sup> Z anglického „transmission matrix“ – matice zachycující pravděpodobnosti přechodu subjektu z každé ratingové třídy do jiné, na diagonále pak pravděpodobnosti setrvání v dané třídě.

<sup>47</sup> Viz Derviz a Kadlčáková (2001).

<sup>48</sup> V současné době v České republice není mnoho firem předmětem hodnocení uznávanými ratingovými agenturami.

<sup>49</sup> Tyto metody, jak bude ukázáno v kapitole páté, mohou např. pomoci vysvětlit vztah mezi rizikem nesplacení úvěru a poměrovými ukazateli spočtenými z finančních výkazů firem. Vzhledem k tomu, že finanční výkazy jsou standardně obsahem informací předkládaných v souvislosti s žádostí o úvěr, jsou data tohoto typu nesporně dostupnější než ratingová hodnocení a pravděpodobnosti jejich změny.

### 2.2.3.1. Podmínky tvorby vlastních modelů

V následující pasáži se zaměřím na podmínky funkčnosti vlastních modelů posuzování bonity. Stupně bonity, které používaný systém přiřazuje novým žadatelům i stávajícím dlužníkům, mohou dle mého názoru nejlépe vystihovat skutečnou míru rizikovosti klientů jen v případě, že zabudovaný algoritmus splňuje následující požadavky:

- i) pokud je založen na odborném zpracování podložených metod;
- ii) pokud byl vytvořen na základě zkoumání souvislostí mezi daty za reprezentativní vzorek potenciálních klientů;
- iii) pokud sleduje stále měnící se strukturu dat o klientech banky, o bankou odmítnutých žádostech a o chybovosti rozhodnutí;
- iv) pokud je schopen adaptace na měnící se relace mezi nákladností různých chybných rozhodnutí.

Banky mohou podle mého názoru splňovat nejvýše podmínky i), iii) a iv), a to pouze pokud zaměstnávají experty na statistické metody. V současné době jim však chybí dostatečně reprezentativní soubory dat, na nichž by systém mohly postavit a ověřovat. Obracejí se proto na firmy specializované na statistická šetření, které reprezentativními vzorky dat disponují. Do hry však vstupuje institut utajení bankovních informací, který externím firmám, byť vybaveným důkladnými znalostmi metod těžení dat,<sup>50</sup> nedovoluje získat některé informace o struktuře bankovních klientů, klíčové pro výkonnost modelu. Domnívám se, že až do doby vytvoření komplexního registru dlužníků bude tato situace, charakterizovaná závislostí bank na firmách specializovaných na těžení dat a omezenou možností adaptovat model na základě tajných bankovních informací, zachována ve všech tuzemských bankách.

V současné době jsou připravovány dva projekty, jejichž úspěšná realizace by pomohla spojit přínosy plynoucí ze splnění výše vyjmenovaných podmínek jednotlivými hráči, a tak by přispěla ke zvýšení efektivity řízení úvěrového rizika: Oba projekty jsou zaměřeny na vytvoření centrálních registrů dlužníků, přístupných komerčním bankám. Registr fyzických osob bude spravovat firma Czech Credit Bureau, registr právnických osob připravuje přímo ČNB. První uvedený projekt bude spuštěn v průběhu května a má již velmi konkrétní podobu.<sup>51</sup> Jeho forma byla převzata od zahraničních společností, které se zabývají se provozem registrů klientských informací

---

<sup>50</sup> „Data mining“.

<sup>51</sup> Oficiální informace o podobě registru připravovaného Českou národní bankou nejsou zatím dostupné. Vyplývá to pravděpodobně mimo jiné ze specifické pozice ČNB vůči komerčním bankám: Přístup supervizora k informacím jednotlivých bank je zřejmě spojen s menší potřebou vyjednávání a zveřejňování informací o povaze projektu.

ve vyspělých tržních ekonomikách.<sup>52</sup> Každá banka, která se bude projektu účastnit, bude jeho správci dodávat pozitivní i negativní informace o vlastních klientech.<sup>53</sup> Svou účastí na projektu získá automaticky možnost obdržet informaci o subjektech, které se u ní ucházejí o úvěrový produkt. Obsahem takové informace bude údaj o objemu poskytnutého úvěrového projektu u jednotlivých bank včetně počtu a objemu zbývajících splátek, po případě splátek, u kterých byl (či je) klient v prodlení.

Vytvoření těchto registrů subjektů čerpajících úvěrové produkty s popisem platební disciplíny přinese komerčním bankám přístup k průběžně aktualizovanému souboru dat za celou populaci žadatelů o úvěr. V souvislosti s přípravou zavedení registru bývá v jeho prospěch nejčastěji zmiňován přínos v podobě zjednodušení získávání informací o dlužnících, kteří nežadají o svůj první úvěr. Registr totiž bance posuzující bonitu svého nového žadatele o úvěr umožní získat on-line informace o závazcích posuzovaného subjektu k jiným bankám. Získání údajů o dobré platební disciplíně vůči jiné bance nepochybně sníží transakční náklady klienta i posuzující banky a urychlí poskytnutí úvěru bonitnímu klientovi. Informace o špatné platební morálce naopak může být pro banku varovným signálem a impulsem k odmítnutí poskytnutí úvěru. Použití registru popsáním způsobem pomůže bankám snížit náklady a chybovost rozhodnutí o poskytnutí úvěru subjektu, který již podobný produkt čerpal.

Za další a z hlediska této práce velmi důležitý přínos registru klientských informací považují možnost výběru vzorků pro sledování struktury dat a pro konstrukci interních bankovních modelů na základě reprezentativních vzorků za celou populaci. Banky již nebudou limitovány použitím dat o vlastních klientech, a splní tak důležitou podmínku tvorby interních modelů – dostatečnou reprezentativnost vzorku.

Ať se banky přikloní k použití vnitřních modelů jako nástroje kontroly nebo jimi přímo nahradí externí systémy,<sup>54</sup> budou potřebovat udržet, respektive rozvinout vnitřní potenciál vlastního modelování.

---

<sup>52</sup> Společnost Czech Credit Bureau je vlastněna italskou firmou Crif, americkou společností Trans Union – společnostmi provozujícími rozsáhlé systémy typu „credit bureau“ - a tuzemskou firmou Aspekt. První zmíněná společnost je rovněž vlastníkem informačního systému EURisc, použitého pro projekt.

<sup>53</sup> Smlouvu o vytvoření sdíleného registru, který má být uveden do provozu v květnu 2002 a k datu zahájení má obsahovat přibližně 1 milion záznamů, podepsalo s firmou Czech Credit Bureau 5 finančních ústavů působících na území ČR (Česká spořitelna, Komerční banka, ČSOB, GE Capital Bank a HVB Czech Republic). Průběžným doplňováním informací i vstupem dalších finančních i nefinančních institucí (počítá se např. i s leasingovými a telekomunikačními společnostmi) do skupiny firem sdílejících informace bude možné dovést registr do takové podoby, aby se stal nejen funkční databází klientů, ale i zdrojem reprezentativních vzorků pro tvorbu modelů řízení úvěrového rizika.

<sup>54</sup> Přiklonění se k třetí variantě – tedy k aplikaci externích modelů bez vlastní adaptace či kontroly – nepovažují z hlediska možností, které přístup k registru přináší, za efektivní využití zdrojů.

### 2.3. Závěr

Jak jsem popsala v podkapitole 2.1., nese s sebou řešení již rozbujelého problému vysoké míry úvěrového rizika ex post vysoké náklady. V nástrojích posuzování bonity klienta ex ante podle mého názoru spočívá velký potenciál jejich snížení.

Systémy měření rizika vytvořené zahraničními finančními institucemi, doporučované v souvislosti s regulačním rámcem navrženým Novou basilejskou dohodou, představují pro svou komplexnost pro české banky poměrně nákladnou investici. Její návratnost je podmíněna vhodnou adaptací původních modelů na české podmínky. Jak bylo zmíněno, vyžadují úpravy některých vstupů zmíněných modelů pro zdejší prostředí (např. odvětvových ratingů či pravděpodobností přesunů subjektů z jedné ratingové skupiny do jiné) nashromáždění dlouhých časových řad a určitou stabilizaci ekonomiky. V předchozí podkapitole navržené řešení této situace, které doporučují i Derviz a Kadlčáková (2001) nebo Buchtíková (1998), spočívá ve vlastní tvorbě systémů, které tyto vstupy nevyžadují.

V rámci své diplomové práce bych ráda přispěla ke zhodnocení toho, do jaké míry je toto řešení vhodné pro současné české podmínky. Jak jsem uvedla v úvodu práce, rozhodla jsem se blíže prozkoumat jednu z četných metod obecně použitelných k tomuto účelu, a to metodu diskriminační analýzy. Ráda bych však zdůraznila, že závěry tohoto zkoumání bude jistě možné lépe zhodnotit jejich porovnáním s výsledky jiných studií, zaměřených na testování dalších již zmíněných metod posuzování bonity: např. logitové či probitové analýzy, metod umělé inteligence či regresních stromů apod.

V následujících kapitolách budu potenciál aplikace diskriminační analýzy na posuzování míry rizikovitosti klientů zkoumat hned z několika hledisek. Nejprve se v rámci kapitoly třetí zaměřím na zhodnocení teoretických možností použití diskriminační analýzy pro posuzování bonity klientů. Jak jsem již zmínila, považuji flexibilitu metody a možnost jejího přizpůsobení pro různé struktury dat o klientech a různé relace nákladů chyb za klíčovou pro její dynamickou funkčnost. Zaměřím se proto v druhé části následující kapitoly na prostor pro zohlednění těchto charakteristik prostředí při analýze.

V rámci kapitoly čtvrté zhodnotím studie, které představují důležité mezníky ve výzkumu použití diskriminační analýzy pro vysvětlení finanční situace firmy. V návaznosti na zhodnocení jejich přínosů se zamyslím nad podmínkami, za kterých je možné používat funkci, vysvětlující finanční situaci podniků v určitém prostředí, pro predikci stavu firem pohybujících se v jiném čase a prostoru.

Za účelem zjištění, do jaké míry lze za pomoci standardních statistických metod nacházet vhodné modely predikce finanční situace českých podniků, jsem provedla praktickou aplikaci metody diskriminační analýzy na vlastní data. Její popis a závěry uvádím v kapitole páté.

### 3. METODOLOGIE MDA<sup>55</sup>

Cílem této práce je přispět k odhalení možností využití metod nového přístupu posuzování bonity podniků v českých podmínkách, a to především pomocí zkoumání potenciálu vícerozměrné diskriminační analýzy. Kapacitu jednotlivých metod lze podle mého názoru nejlépe posoudit pomocí zkoumání rozsahu teoretických možností jejich použití a konkrétních výsledků jejich aplikace.

Prvním z uvedených hledisek se budu zabývat nyní. Po shrnutí základních rysů obecného modelu diskriminační analýzy v podkapitole 3.1. se zaměřím zejména na vlastnosti diskriminační funkce, jejichž zachycení považuji pro úspěšné použití v managementu úvěrování za klíčové. Středem mého zájmu bude testování vhodnosti zvolené funkce pro predikci, tedy možnost ověření správnosti klasifikace (podkapitola 3.2.1.), možnost eliminace chyb a zahrnutí nákladů jednotlivých typů chyb do konstrukce modelu, zohlednění poměru bonitních a pochybných klientů apod. (podkapitola 3.2.1.2.1.) a způsob využití hodnot odhadů parametrů pro další analýzy (podkapitola 3.2.2.).

#### 3.1. Teoretické základy diskriminační funkce

Diskriminační analýza je metodou vhodnou ke klasifikaci pozorování do dvou nebo více skupin. Jemnost členění zvolená pro analýzu závisí jak na skutečném cíli analýzy, tak na struktuře dat, která jsou k dispozici. Protože v rámci empirické analýzy uvedené v kapitole páté použiji členění do dvou skupin, zaměřím se v následujícím textu na výklad právě této formy modelu. Nejprve stručně vyložím obecnou Fischerovu formu modelu,<sup>56</sup> následně navážu vysvětlením možností modifikace funkce pro potřeby bankovní praxe. Budu vycházet zejména ze směrů úprav, které naznačili Afifi a Clark (1990) a McLachlan (1992).

##### 3.1.1. Obecný model diskriminační analýzy

Model diskriminační analýzy byl vytvořen již v roce 1936 R. A. Fischerem.<sup>57</sup> Cílem analýzy diskriminace pozorování do dvou skupin je nalezení funkce, reprezentující nadrovinu, která nejlépe odděluje předem definované shluky pozorování, rozmístěné v prostoru, jehož dimenze je dána počtem vstupních proměnných. Pokud je taková funkce vhodně zvolena, je za její pomoci možné rozlišovat mezi jednotlivými pozorováními. R. A. Fischer funkci popsal pro případ dvou skupin následovně:<sup>58</sup>

---

<sup>55</sup> Vícerozměrná diskriminační analýza (zkratka vychází z anglického „Multiple Discriminant Analysis“).

<sup>56</sup> Podrobným výkladem matematických vztahů, stojících za obecnou formou diskriminační analýzy, se zabývá např. Sekerka (1998).

<sup>57</sup> Viz Fischer (1938), cit. např. Eisenbeis (1977).

<sup>58</sup> V obecném případě  $n$  skupin je třeba nalézt  $n-1$  nadrovin. Fischer se zabýval hledáním dvou nadrovin, které by nejlépe oddělovaly tři typy kosatců. Viz. Fischer (1936) cit. např. Eisenbeis (1977).

$$Z = a_1X_1 + a_2X_2 + \dots + a_pX_p, \quad (3.1.)$$

kde  $a_1, \dots, a_p$  jsou koeficienty diskriminace a  $X_1, \dots, X_p$  jsou vybrané nezávislé proměnné, nejlépe vysvětlující rozdělení do skupin.

Aby bylo možné polohu pozorování v prostoru vzhledem ke zvolené nadrovině porovnávat a odhadovat tak příslušnost nových pozorování do jednotlivých skupin, je množina všech možných realizací této funkce, označená například  $R$ , rozdělena na dvě části  $R_1$  a  $R_2$ . V ideálním případě by rozdělení oboru hodnot splňovalo následující podmínky:

$$R = R_1 \cup R_2$$

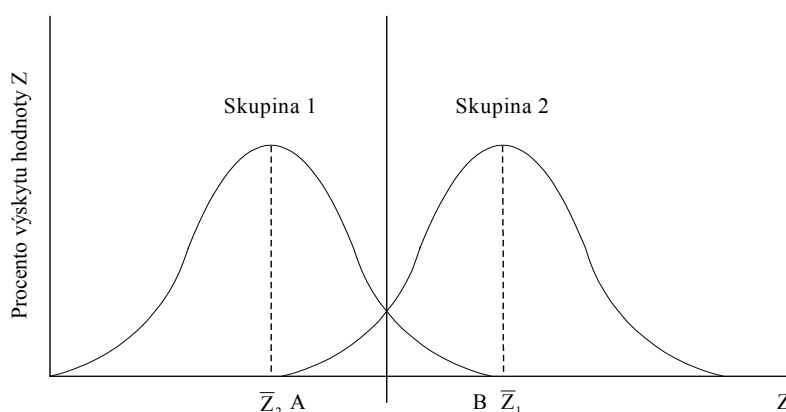
$$R_1 \cap R_2 = \emptyset.$$

Diskriminační analýza by v takovém případě přiřadila podle hodnoty funkce  $Z$  pozorování právě do jedné ze skupin. Hodnota diskriminační funkce, odpovídající umístění hraniční čáry, je v obecném případě dána následovně:

$$C = \frac{\bar{Z}_1 + \bar{Z}_2}{2}, \quad (3.2.)$$

kde  $\bar{Z}_i$  je střední hodnota diskriminační funkce pro  $i$ -tou skupinu.<sup>59</sup> Jedná se tedy o polovinu vzdálenosti mezi středními hodnotami funkce pro každou ze skupin.

V reálném světě však pozorování z obou skupin generují hodnoty na obou stranách hraniční čáry – rozdělení hodnot pro jednotlivé skupiny se překrývají. Pro případ normálního rozdělení hodnot funkce pro obě skupiny zachycuje překrytí obrázek 1. Pozorování generující hodnotu funkce  $Z$  v intervalu vymezeném na obrázku body A a B nemusí být diskriminační funkcí správně klasifikována.



**obrázek 1** Teoretické rozdělení hodnot funkce  $Z$  pro 2 skupiny. V intervalu mezi body A a B se překrývají obory hodnot funkce za obě skupiny.

<sup>59</sup> Proměnná  $i$  nabývá hodnot z množiny  $\{1;2\}$ .

K minimalizaci chyby klasifikace vede nalezení takové funkce, která generuje nejmenší velikost intervalu, do něhož padají hodnoty funkce pro obě skupiny (šedou zónu).<sup>60</sup> Jak je vidět z obrázku, je velikost šedé zóny negativně závislá na vzdálenosti středních hodnot funkce a pozitivně na velikosti rozptylu hodnot obou skupin. Chyba diskriminace funkce je tedy minimalizována, pokud je maximalizována následující veličina:

$$D_2 = \frac{(\bar{Z}_1 - \bar{Z}_2)^2}{S_Z^2}, \quad (3.3.)$$

kde  $\bar{Z}_i$  je opět střední hodnota diskriminační funkce pro  $i$ -tou skupinu a  $S_Z^2$  je rozptyl  $Z$ . Veličina  $D_2$  nese název Mahanobilisova vzdálenost, a jak je vidět ze vzorce, je druhou mocninou standardizovaného rozdílu mezi středními hodnotami funkce. Proměnné  $X_1, \dots, X_n$  a koeficienty  $a_1, \dots, a_n$  jsou při konstrukci optimální diskriminační funkce vybírány tak, aby hodnota  $D_2$  byla maximalizována.<sup>61</sup>

Výzkum a praktická aplikace Fischerovy diskriminační funkce přinesly množství dalších poznatků, umožňujících rozvoj této metody. Vytvoření dalších statistických postupů spojených s problémem klasifikace, jako například testů hypotéz o přínosu jednotlivých proměnných či metod odhadu chyb klasifikace, si vyžádalo přijetí několika zásadních předpokladů o proměnných. Na proměnné, které jsou pro klasifikaci použity, klade model nadefinovaný v současně používaných statistických programech následující požadavky:<sup>62</sup>

- i) náhodnost výběru vzorku, který je použit k vytvoření diskriminační funkce;
- ii) normální rozdělení nezávisle proměnných v rámci obou skupin;
- iii) homogenita kovariančních matic za obě skupiny.

Splnění předpokladu i) je v praxi dosažitelné, pokud existuje dostatek dostupných dat za zástupce obou zvolených skupin. Při empirických studiích zaměřených na závislost bonity klientů na finančních ukazatelích jsou obecně k dispozici dva způsoby výběru vzorku. První ze způsobů je skutečným náhodným výběrem vzorku z velké skupiny podniků, u kterých jsou k dispozici vhodná data. Druhý způsob je používán v případě, že není v dosahu dostatečně velká množina kvalitních výkazů podniků obou skupin. Při náhodném výběru z příliš malé množiny totiž není zaručeno

<sup>60</sup> Označení šedá zóna zavedl Altman (1968). Na obrázku 1 je šedá zóna označena krajními body A a B.

<sup>61</sup> Na výpočtu  $D_2$  je založena většina testů statistické významnosti vlivu proměnných, na jejichž základě jsou proměnné zahrnovány do modelu, po případě z něho vylučovány (F test, Wiksova Lambda, Parciální lambda). Definici testů nabízí např. McLachlan (1992) nebo Anderson (1958). Využití testů uvádím v páté kapitole.

<sup>62</sup> Platí to i pro program Statistica, použitý pro vytvoření modelového příkladu v této práci.

zastoupení reprezentantů obou skupin ve vzorku, odpovídající skutečnému poměru obou skupin v populaci. Řešením je výběr takové části vzorku ze skupiny bonitních podniků, jaká odpovídá pozorovanému výskytu případů bonitních klientů v celé populaci. Stejný postup je aplikován na výběr vzorku podniků s nízkou bonitou. Pokud je poměr dobrých a špatných úvěrů odhadnut například na 7:3 a velikost vzorku je stanovena na 100 podniků, je náhodně vybráno nejprve 70 podniků ze skupiny dobrých a pak 30 podniků ze skupiny špatných. Na takto uměle sestavený vzorek je následně aplikována analýza.<sup>63</sup>

Splnění předpokladu ii) souvisí přirozeně s realizací předpokladu i). Nutno však zdůraznit, že pouze do určité míry: U číselných proměnných je normalita rozdělení hodnot nezávisle proměnných pro dostatečně velké náhodné vzorky dosažitelná. Mezi nezávisle proměnnými, používanými pro diskriminaci do skupin, jsou však často kvalitativní proměnné, které mají podobu slovních charakteristik jednotlivých pozorování.<sup>64</sup> Mezi takové proměnné patří například vzdělání, využití úvěru, pohlaví, minulý vztah klienta a banky, apod. Ve statistice takové proměnné většinou převádíme na nominální hodnoty (0,1, po případě -1, +1), aby je bylo možné zahrnout do funkce. Výzkumy ukázaly, že přestože takové proměnné nesledují normální rozdělení, může jejich použití v diskriminační analýze pomoci zlepšit klasifikaci. Někteří odborníci navíc uvádějí, že ani u číselných proměnných nevede nesplnění předpokladu normality rozdělení k nepoužitelnosti testů statistické významnosti.<sup>65</sup>

Předpoklad iii) vyžaduje, aby proměnné za obě skupiny sledovaly porovnatelné rozdělení. Je přijat především z důvodu konstrukce testů statistické významnosti, které jsou založeny na společném rozptylu proměnných za obě skupiny.<sup>66</sup> Pokud například některá z proměnných vykazuje pro jednu skupinu vysokou pro druhou skupinu naopak velmi nízkou varianci, může být společný rozptyl relativně nízký a poukazovat na statistickou významnost závislosti tam, kde ve skutečnosti není.

K detekci této vlastnosti slouží tzv. Boxův M-test.<sup>67</sup> Ošetření negativních výsledků těchto testů je možné provádět například vyřazením odlehlých pozorování<sup>68</sup> či pozitivními transformacemi proměnných tak, aby se odlehlé hodnoty přiblížily střední hodnotě. Protože je porovnávání rozdělení proměnných za obě skupiny prováděno pomocí srovnání inverzních matic, může být provedení testu

---

<sup>63</sup> Takový postup jsem zvolila i v případě praktického příkladu, uvedeného v páté kapitole. Popis výběru vzorku je uveden v podkapitole 5.2.3.

<sup>64</sup> V anglické literatuře „dummy variables“.

<sup>65</sup> Viz např. studie dopadů nedodržení předpokladů při aplikaci MDA, provedená Eisenbeisem (1977).

<sup>66</sup> Viz výpočet Mahanobilisovy vzdálenosti (podkapitola 3.1.1), na níž je založena většina testů statistické významnosti. Definice viz např. McLachlan (1992), Affifi a Clark (1990).

<sup>67</sup> Podle G. E. P. Boxe, který test publikoval v roce 1949 v časopise *Biometrika* (Vol. 36, p. 317-346). Podrobný výklad parametrických testů shodnosti kovariančních matic nabízí např. Anderson (1958). Boxův M-test je jako jiné parametrické testy poměrně citlivý na existenci odlehlých pozorování. Sen a Puri (1971) proto navrhli test shodnosti kovariančních matic, jehož aplikace nepodléhá splnění žádných předpokladů o rozdělení proměnných. Jejimi autory je doporučována v případě nesplnění předpokladu normality.

<sup>68</sup> Tzv. „outliers“.



znemožněno singularitou některé z matic.<sup>69</sup> Ošetřením této vlastnosti může být např. vyřazení proměnných, které jsou velmi silně korelovány s jinými vstupy.<sup>70</sup>

### 3.2. Využití výsledků MDA pro měření úvěrového rizika

Obecně lze rozlišovat mezi dvěma základními způsoby využití výsledků MDA pro měření úvěrového rizika. Jednou z možností je přímá aplikace zvolené diskriminační funkce na data o nových klientech za účelem predikce jejich bonity. Další způsob využití výsledků MDA spočívá ve vytipování významných závislostí, důležitých pro další analýzy. Oběma zmíněnými možnostmi využití MDA v bankovní praxi se budu postupně zabývat v následujících odstavcích.

#### 3.2.1. Predikce finančního zdraví

První z možností využití výsledků diskriminační analýzy je přímá aplikace funkce na data o nových klientech, která přináší odhady jejich rozdělení do skupin. Tento způsob využití je podmíněn výběrem kritéria diskriminace s takovou jemností členění, jaká bude použita při predikci situace ohledně nových pozorování.

Rozsah možností využití funkce pro předpovědi je dále ovlivněn mírou chyby, jaké se při klasifikaci dopouští funkce zahrnující kombinaci proměnných zvolených na základě zhodnocení statistické významnosti jejich vlivu. Před využitím výsledků diskriminační analýzy pro zmíněný účel je proto vhodné podrobit funkci zkoumání nad rámec porovnávání statistické významnosti jednotlivých vlivů.

V případě klasifikace do dvou skupin mohou nastat dvě možné realizace chybné klasifikace.<sup>71</sup> Výskyt obou typů chyb může být shrnut pomocí tzv. klasifikační matice, jejíž zobrazení znázorňuje tabulka 1:

Skutečné rozdělení	Rozdělení předpovězené funkcí	
	Ztrátový	Bonitní
Ztrátový	$S_1$	$\alpha$
Bonitní	$\beta$	$S_2$

**tabulka 1** Klasifikační matice pro rozdělení do skupin „Ztrátový“ a „Bonitní“.

Symbole  $S_1$  a  $S_2$  reprezentují v matici klasifikace počet podniků každé skupiny, které byly diskriminační funkcí zařazeny správně, jejich součet pak dává celkový počet správně klasifikovaných podniků. Prvky ležící mimo diagonálu klasifikační matice zachycují chybné klasifikace. V bankovníctví mají následující interpretaci: Na jedné straně může být za bonitního žadatele o úvěr považován podnik, který ve skutečnosti nebude schopen úvěr splácet. Taková chyba bývá označována

<sup>69</sup> Viz např. Eisenbeis (1977).

<sup>70</sup> Diskusí jednotlivých opatření a volbou jejich kombinace v konkrétním případě empirické analýzy dat za české podniky se zabývám v podkapitole 5.2.4.

<sup>71</sup> Obecně platí, že při klasifikaci do  $n$  skupin je počet typů chyb  $t$  dán jako  $t = n(n-1)$

jako chyba typu  $\alpha$  a představuje pro banku dodatečné náklady plynoucí z krytí nedobytné půjčky. Chyba diskriminace typu  $\beta$  je naopak označením situace, kdy banka na základě analýzy odmítne úvěrovat podnik, který by byl disciplinovaným dlužníkem.

Chyba typu  $\alpha$  bývá bankami pocíťována jako bolestivější, neboť představuje přímé náklady. Přílišný výskyt chyby typu  $\beta$  je však také nadměru nepříznivý, protože v sobě skrývá ušlý zisk z neuzavřených výhodných obchodů.<sup>72</sup> Je proto v zájmu bank, aby sledovaly, jakou míru obou chyb<sup>73</sup> vykazuje jimi zvolená metoda, a snažily se co nejvíce zamezit výskytu obou chyb, po případě zmírnit jejich dopad.<sup>74</sup>

Podkapitola 3.2.1.1 dává přehled o metodách zjišťování schopnosti klasifikace, jakou vykazuje zvolená funkce.

### 3.2.1.1. Praktické ověření schopnosti klasifikace

Pro ověření schopnosti diskriminační funkce rozdělovat pozorování správně do skupin jsou používány různé metody, jejichž vhodnost v dané situaci závisí zejména na velikosti vzorku, který je k dispozici. Následující pasáže shrnují podstatu tří nejpoužívanějších metod validace funkce a zmiňují nejdůležitější aspekty příhodnosti jejich použití. Porovnání těchto tří metod s dalšími alternativními postupy vhodnými k ověření klasifikační schopnosti funkce nabízí např. Eisenbeis (1977).

#### 3.2.1.1.1. Empirická metoda

Při použití empirické metody je diskriminační funkce aplikována na data, na jejichž základě byla sestavena. Tento proces je jednoduchou a pravděpodobně nejdostupnější metodou validace diskriminační funkce. Ve skutečnosti však mohou být výsledné poměry výskytu klasifikační chyby spočtené na základě aplikace funkce na výchozí data značně podhodnocené. Výsledek testu empirickou metodou totiž nepřináší žádné upozornění na nízkou obecnost funkce. Proto je tato metoda samostatně využívána pouze v případech, kdy není k dispozici dostatečné množství dalších dat či potřebných kapacit, aby mohlo být využito výhod některé z dalších metod validace.

#### 3.2.1.1.2. Křížová metoda

Potenciální vychýlení odhadu klasifikační schopnosti funkce, kterou může přinést použití empirické metody, je možné vyšetřit mimo jiné pomocí křížové metody: Vstupní data jsou před zahájením analýzy náhodně rozdělena na dvě části. Po vypočtení diskriminační funkce na základě jedné části vzorku dat je její schopnost diskriminace testována aplikací vztahu na druhou část

<sup>72</sup> Viz úvaha nad rozdíly v nákladech obou typů chyb uvedená v podkapitole 3.2.1.2.2.

<sup>73</sup>  $(S_1 + S_2) / (S_1 + S_2 + \alpha + \beta)$  = podíl celkové správné klasifikace,  $(S_1) / (S_1 + \alpha)$  = podíl správné klasifikace ztrátových klientů,  $(S_2) / (S_2 + \beta)$  = podíl správné klasifikace bonitních klientů.

<sup>74</sup> Využitím různých analýz, zajišťováním pomocí derivátů apod.

vzorku.<sup>75</sup> Výstupem této metody jsou odhady chybné klasifikace sestavenou funkcí, jejichž vychýlení klesá s reprezentativností sekundárního vzorku.

Prékážkou použití této metody ověření schopnosti funkce diskriminovat bývá však nedostatek vstupních dat. Rozdělení malého vzorku na více částí má dopad na reprezentativnost vzorku dat, použitého jako vstup do analýzy.

#### 3.2.1.1.3. Metoda kapesního nože

Alternativou křížové a empirické metodě, rovněž vhodnou k testování klasifikační schopnosti funkce, je tzv. metoda kapesního nože,<sup>76</sup> spočívající v několika opakujících se krocích. Při jejím použití je nejprve vyčleněno jedno pozorování, reprezentující například bonitního klienta. Za použití zbývajících dat je pak spočtena diskriminační funkce, která je následně použita ke klasifikaci předem vyčleněného pozorování. Po opakování této procedury pro všechna pozorování reprezentující bonitní klienty je možné na základě výsledného počtu pozorování, která byla označena za reprezentanty špatných žadatelů o úvěr, spočítat poměr chybné klasifikace typu  $\alpha$ . Analogický postup, v jehož rámci jsou ze vzorku postupně vyčleňována pozorování reprezentující špatné klienty, je cestou ke zjištění chyby typu  $\beta$ . Metoda kapesního nože, nabízená i některými statistickými programy, přináší jen velmi málo vychýlené odhady a je použitelná i v případě menšího vzorku. Nevýhodou je však její časová náročnost.

#### 3.2.1.2. Zohlednění specifických rysů prostředí

Cílem podkapitoly 3.2.1.1. bylo shrnout různé metody rozdělení dat ze vzorku, jejichž pomocí je možné ohodnotit klasifikační schopnost zvolené funkce. Důležitou roli při výběru vhodné diskriminační funkce hrají i specifika zkoumaného prostředí - například pravděpodobnost, s jakou bude banka čelit nebonitnímu klientovi, nebo náklady spojené s výskytem každého z typů chybné klasifikace. V následujících pasážích budu proto pokračovat nástinem možností zahrnutí těchto aspektů do diskriminační analýzy.

Podkapitola 3.2.1.2.1. je zaměřena na vysvětlení a využití konceptu pravděpodobnosti a priori. Pasáž 3.2.1.2.2. diskutuje možnost zahrnutí odlišné velikosti nákladů na oba typy chyb do analýzy, a to jak pomocí posunů hraniční čáry (podkapitola 3.2.1.2.2.1.), tak za využití tzv. aposteriorních pravděpodobností (podkapitola 3.2.1.2.2.2.).

---

<sup>75</sup> Tzv. sekundární data.

<sup>76</sup> Někdy je nazývána též Lachenbruchova metoda či U-metoda.

### 3.2.1.2.1. Pravděpodobnost a priori

Pro úvěrová rozhodnutí je velmi důležitá znalost poměru zastoupení bonitních a pochybných klientů v celé populaci žadatelů. Tuto informaci přináší pravděpodobnost a priori.<sup>77</sup> Pokud je empiricky zjištěno, že z celkového počtu žadatelů je 70 % bonitních a 30 % pochybných,<sup>78</sup> jsou pravděpodobnosti a priori příslušnosti k dobrým a špatným klientům po řadě 70 a 30 procent. Pokud bychom v takovém případě náhodně vybrali jednoho uchazeče a považovali ho bez jakékoli analýzy za bonitního klienta, byla by naše klasifikace se sedmdesátiprocentní pravděpodobností správná a s třicetiprocentní pravděpodobností chybná. Při velkém počtu takových náhodných výběrů klientů a poskytování půjček by byla banka ze 70 % úspěšná. Chyba typu  $\alpha$  by však v tomto případě byla stoprocentní.

Pravděpodobnosti a priori je možné pro klasifikaci klientů využít efektivněji, než jak tomu bylo ve výše uvedeném ilustračním příkladě. Na základě znalosti tohoto údaje lze pozitivně ovlivnit konstrukci diskriminační funkce například tak, jak naznačují Afifi a Clark (1990): Aby bylo dosaženo snížení chyby klasifikace, může být informace o apriorní pravděpodobnosti zapojena do konstrukce hraniční čáry mezi hodnotami diskriminační funkce pro jednotlivé skupiny žadatelů o úvěr.

Celková pravděpodobnost chybné klasifikace je dána následovně:

$$Q = q_1 * r_1 + q_2 * r_2 , \quad (3.4.)$$

kde je:

- $q_1$  apriorní pravděpodobnost příslušnosti k špatným klientům,
- $r_1$  pravděpodobnost chybného zařazení špatného klienta do skupiny bonitních (chyba  $\alpha$ )
- $q_2$  apriorní pravděpodobnost příslušnosti k bonitním klientům,
- $r_2$  pravděpodobnost chybného zařazení bonitního klienta do skupiny špatných (chyba  $\beta$ ).

Při uvažování standardního modelu popsaného v podkapitole 3.1.1 a za daných apriorních pravděpodobností je bod C, který dělí interval oboru hodnot diskriminační funkce, zvolen následovně:

<sup>77</sup> Dále v textu též *apriorní pravděpodobnost*.

<sup>78</sup> Vyjádření „empiricky zjištěno“ jsem zde použila s jistou nadsázkou. V současné situaci se vždy bude jednat pouze o odhad. Banka totiž informaci o apriorních pravděpodobnostech může získat z poměru bonitních a nebonitních klientů, kterým úvěr v minulosti poskytla. Skutečnou platební disciplínu klientů, kterým úvěr neposkytla, v současnosti, kdy ještě neexistuje registr dlužníků, nezná. Ve výsledném poměru tak nebudou zohledněny podniky, které v minulosti odmítla a apriorní pravděpodobnosti budou vychýleny na základě míry chybné klasifikace typu  $\alpha$ . Odhad bude příliš pesimistický, neboť nezohlední odmítnuté žádosti, které by ve skutečnosti generovaly dobrý úvěrový vztah.

Pokud by byl měřítkem apriorní pravděpodobnosti aproximativně zvolen poměr prosperujících a upadajících podniků v celé ekonomice, bude odhad též vychýlen. Lze totiž očekávat, že velké procento nejvíce prosperujících podniků nebude v důsledku možnosti získání jiného, levnějšího financování o úvěr vůbec žádat.

$$C = \frac{\bar{Z}_1 + \bar{Z}_2}{2} + \ln \frac{q_1}{q_2}, \quad (3.5.)$$

kde  $\bar{Z}_1$ , respektive  $\bar{Z}_2$  jsou opět střední hodnoty diskriminační funkce pro jednotlivé skupiny. Logaritmická funkce je na podíl pravděpodobností a priori aplikována s cílem posunout bod C od aritmetického průměru středních hodnot podle relace velikosti obou skupin. Pokud je v populaci zastoupeno více bonitních klientů, bude platit:

$$\frac{q_1}{q_2} < 1. \quad (3.6.)$$

Logaritmus této hodnoty bude přirozeně menší než 0. Bod C, dělicí obor hodnot, se po ose posune směrem doleva, bude odpovídat nižšímu číslu. Zvětší se tak podmnožina oboru hodnot  $R_2$ , jejíž hodnoty budou generovat přiřazení k bonitním klientům. Pokud bude v populaci větší počet nebonitních klientů, proběhne posun v opačném směru, zvětší se oblast příslušná očekávání špatných úvěrů.

Z tvaru funkce přirozeného logaritmu plyne, že posun bodu C v přibližně stejné proporci doleva i doprava bude probíhat pouze v případech, kdy pravděpodobnosti a priori budou v poměru okolo 1:1. Protože je logaritmická funkce konkávní, bude při zvýšení  $q_2$  (zastoupení bonitních klientů v populaci) bod C posunut doleva více, než by byl posunut doprava při stejném snížení  $q_2$ . Ošetření problému možnosti chybné klasifikace ve výše vyložené podobě je tedy pouhou aproximací.<sup>79</sup>

#### 3.2.1.2.2. Náklady chybné klasifikace

Dalším hlediskem posuzování klasifikační schopnosti funkce je poměr relativních nákladů vyplývajících z jednotlivých typů chyb. V následujících pasážích se budu zabývat dvěma metodami, pomocí nichž lze velikost nákladů obou typů chyb zohlednit v analýze: Jedním z nich je posun dělicího bodu oboru hodnot, analogický posunům v důsledku rozdílných apriorních pravděpodobností.<sup>80</sup> Dalším řešením zohlednění rozdílných nákladů klasifikace je stanovení hodnoty tzv. aposteriorní pravděpodobnosti<sup>81</sup> příslušnosti do skupiny, od které bude klasifikace diskriminační funkcí dále ověřována dodatečnou analýzou.

Jejich zahrnutí do výpočtu poměru apriorních pravděpodobností bonitních a pochybných podniků tak bude naopak příliš optimistické.

<sup>79</sup> Příklad posunu logaritmické funkce při velkých rozdílech v zastoupení skupin v populaci musel být ošetřen jinou funkcí. Vzhledem k tomu, že zdrojové kódy statistických programů jsou předmětem obchodního tajemství, nedisponuji informací, jak je v jejich rámci tento efekt ošetřen.

<sup>80</sup> Níže uvedený výklad tohoto postupu také čerpá ze stejného zdroje, z postupu navrženého Afifim a Clarkem (1990).

<sup>81</sup> Vysvětlení pojmu zahrnuje podkapitola 3.2.1.2.2.2.

## 3.2.1.2.2.1. Posuny dělicího bodu oboru hodnot

Pokud vedení úvěrového oddělení dospěje k názoru, že výskyty různých typů chyb přináší rozdílné dodatečné náklady, může zjištěný vztah zohlednit při konstrukci diskriminační funkce, kterou bude požívat pro posouzení bonity klientů.

Tyto náklady lze zjednodušeně vyjádřit např. následovně:

$$c_{\beta} = c(\sum_i r_{L_i}, \dots), \quad (3.7.)$$

kde:

$c_{\beta}$  značí náklady chyby typu  $\beta$ ,

$r_{L_i}$  je úroková míra z úvěru, pokud by byl  $i$ -tému bonitnímu klientovi poskytnut.

Náklady chyby typu  $\beta$  jsou tedy především funkcí ušlých zisků z úroků placených bonitními úvěrovanými subjekty.

Naproti tomu náklady chyby typu  $\alpha$  je možné vyjádřit jako funkci ztráty z poskytnutí úvěru subjektu, který úvěr nezaplatil, a dále funkcí rizika ztráty důvěryhodnosti v souvislosti se zveřejněním této skutečnosti:

$$c_{\alpha} = c\left\{\sum_j (L_j + \Delta\sigma_j), \dots\right\}, \quad (3.8.)$$

kde:

$c_{\alpha}$  jsou náklady chyby typu  $\alpha$ ,

$L_j$  značí objem půjčky, poskytnuté  $j$ -tému nebonitnímu klientovi,

$\sigma_j$  symbolizuje zvýšení rizika vystavení zvýšenému výběru hotovosti, plynoucímu ze ztráty důvěry banky v souvislosti s veřejným odhalením nedobytnosti úvěru.<sup>82</sup>

Dělicí bod oboru hodnot diskriminační funkce, který je orientován na minimalizaci nákladů spojených s chybnou klasifikací, pak může být zvolen následovně:

$$C = \frac{\bar{Z}_1 + \bar{Z}_2}{2} + K, \quad (3.9.)$$

$$\text{kde } K = \ln \frac{q_2 * c_{\alpha}}{q_1 * c_{\beta}} \quad (3.10.)$$

<sup>82</sup> Tato složka je podle mého názoru relevantní pouze u velkých objemů úvěrů.

K možnosti zohlednění poměru apriorních pravděpodobností, popsanému v podkapitole 3.2.1.2.1, přibývá možnost uvažovat relaci nákladů obou typů chyb: Pokud je chyba typu  $\beta$  méně nákladná, než chyba opačná,<sup>83</sup> tedy pokud

$$c_{\beta} < c_{\alpha}, \quad (3.11.)$$

platí:

$$\ln \frac{c_{\alpha}}{c_{\beta}} > 0. \quad (3.12.)$$

Dělicí bod oboru hodnot  $C$  se při takovém poměru nákladů chyb posune směrem doprava. Zvětší se tak interval hodnot  $Z$ , který bude generovat zařazení klienta do skupiny nebonitních uchazečů o úvěr, banka bude při poskytování úvěrů na základě této hraniční hodnoty obezřetnější. Jedná se o posun opačný tomu, který jsem popsala v podkapitole 3.2.1.2.1.

V případě výskytu nerovnosti apriorních pravděpodobností a zároveň nerovnosti nákladů obou chyb klasifikace je použití obou popsaných ošetření vedoucích k posunům dělicího bodu provázeno jistým trade-off: Při ošetření obou problémů posunem dělicího bodu by docházelo ke vzájemnému vyrušení posunů. V takové situaci je smyslupné zvolit ošetření pouze jedné z nerovností posunem hraniční čáry (například rozdílného poměru zastoupení reprezentantů obou skupin v populaci). Druhou nerovnost – nerovnost nákladů chybné klasifikace – je možné řešit například pomocí stanovení meze, od které bude nutné zapojit dodatečnou analýzu. Tato metoda je přiblížena v následující pasáži, zabývající se aposteriorními pravděpodobnostmi příslušnosti pozorování do jednotlivých skupin.

#### 3.2.1.2.2.2. Aposteriorní pravděpodobnost

Pro zkoumání klasifikační schopnosti diskriminační funkce je přínosné stanovit pravděpodobnost příslušnosti do jedné či druhé skupiny, kterou každému pozorování přiřazuje diskriminační funkce. Jak uvádí např. Afifi a Clark (1990) můžeme tuto informaci obdržet ze vztahu:

$$\Pi_1 = \frac{1}{1 + e^{-Z+C}}, \quad (3.13.)$$

kde  $\Pi_1$  je pravděpodobnost, že pozorování patří do skupiny 1. Pravděpodobnost příslušnosti ke skupině 2 je přirozeně doplňkem  $\Pi_1$ . Obě popsané pravděpodobnosti jsou spočteny až po provedení diskriminační analýzy, nesou proto název aposteriorní pravděpodobnosti.<sup>84</sup> Aposteriorní pravděpodobnosti pro vzorek populace slouží jako nástroj interpretace výsledků klasifikace. Pokud se banka chce zajistit proti neblahým důsledkům chyb klasifikace, může být obsahem její strategie

<sup>83</sup> Náklady spojené se ztrátami banky z nedobytných úvěrů a s očišťováním úvěrových portfolií jsou nepochybně vyšší než náklady ušlých zisků z přijatých úroků.

stanovení míry aposteriorní pravděpodobnosti požadované k přijetí klasifikace jako rozhodující. U podniků, jejichž aposteriorní pravděpodobnosti příslušnosti k jedné z vymezených skupin se budou pohybovat okolo 50 %, se banka na výsledky klasifikace nebude spoléhat a podnikne alternativní analýzu.

Hodnot aposteriorních pravděpodobností je možné využít k úpravě výsledků diskriminační analýzy i při existenci rozdílných nákladů na různé typy chyb. Vezměme příklad, uvažovaný výše, kde poskytnutí úvěru nebonitní firmě (chyba typu  $\alpha$ ) představuje relativně vyšší náklady než odmítnutí bonitního klienta (chyba typu  $\beta$ ). Vyčlenění pozorování, jejichž klasifikace by mohla vést k nákladnější chybě, tedy chybě typu  $\alpha$ , může úvěrové oddělení docílit tím, že stanoví hranici aposteriorní pravděpodobnosti pouze těch pozorování, která byla diskriminační analýzou zařazena do skupiny dobrých úvěrů. Bude tedy například dodatečně zevrubně analyzovat ty případy, které v rámci diskriminační analýzy vykazaly aposteriorní pravděpodobnost příslušnosti k bonitním dlužníkům v intervalu 50-80 %. Aposteriorní pravděpodobnost příslušnosti ke špatným dlužníkům nad 50 % bude naopak brát jako signál k okamžitému odmítnutí poskytnutí úvěru. Následující tabulka ilustruje obě navržené strategie zamezení klasifikačním chybám.

Podnik	Aposteriorní pravděpodobnost příslušnosti k		Výsledek analýzy	
	bonitním klientům	špatným klientům	a	b
A	0.9	0.1	poskytnout	poskytnout
B	0.1	0.9	odmítnout	odmítnout
C	0.58	0.42	další analýza	další analýza
D	0.42	0.58	<b>další analýza</b>	<b>odmítnout</b>

**tabulka 2** Strategie zamezení chybám klasifikace.

Při sledování strategie zamezení oběma chybám i strategie potlačení především chyby  $\alpha$  by byla poskytnuta půjčka podniku A a odmítnuto úvěrování podniku B. Další analýze by byl na základě obou strategií podroben podnik C. Vztah k podniku D je u každé strategie odlišný. Banka, která by se snažila zamezit oběma klasifikačním chybám ve stejné míře (sledovala by strategii a), by podrobila další analýze i podnik D. Banka, pro kterou by chyba  $\beta$  představovala nižší náklady, a která by se proto zaměřila primárně na eliminaci chyby  $\alpha$  (strategie b), by se naopak analýzou výkazů podniku D dále nezabývala a úvěrování by odmítla.

Postupy, které jsem vybrala k ilustraci možnosti minimalizace důsledků chybné klasifikace a popsala v rámci pasáže 3.2.1.2.2., jsou zaměřeny na optimální výběr bodu dělicího obor hodnot diskriminační funkce na dvě podmnožiny, respektive na výběr meze, do které je výsledek funkce

<sup>84</sup> Také „pravděpodobnosti ex post“.



věrohodný. Při aplikaci popsaných metod využití znalosti hodnot apriorních i aposteriorních pravděpodobností a relativních nákladů jednotlivých typů chyb nejsou, jak je vidět, ovlivňovány hodnoty diskriminačních koeficientů  $a_1, a_2, \dots, a_n$ . Zásahy se v podstatě týkají jen polohy hraniční hodnoty funkce  $Z$ , respektive hraniční hodnoty aposteriorní pravděpodobnosti. K dosažení modifikace výsledků analýzy na základě upřednostňování některého z popsaných hledisek proto není třeba přepočítávat koeficienty stanovené statistickým programem. Cestou k dosažení zohlednění údajů o apriorních pravděpodobnostech je jejich stanovení ještě před provedením vlastní analýzy. Využití znalosti rozdílných nákladů pomocí stanovení hranic aposteriorních pravděpodobností tak, jak je nastíněno výše, je pak pouze otázkou podrobnějšího zkoumání standardního výstupu statistického programu.

### 3.2.2. Vytipování důležitých proměnných

Podkapitola 3.2.1. byla věnována využití výsledků diskriminační funkce ke klasifikaci pozorování s neznámou hodnotou vysvětlované proměnné. Jak jsem zmínila v úvodu, je uplatnění výsledné funkce v predikci nadcházející situace podmíněno použitím kritéria diskriminace s takovou jemností členění, jaká bude použita při analýze nových pozorování. Mnohdy však tvůrce v době provedení analýzy nedisponuje souborem pozorování, který je rozčleněn do skupin s jemností požadovanou pro úvěrová rozhodnutí.<sup>85</sup> Navíc jsou v některých oblastech úvěrování žadatelé a objemy půjček natolik heterogenní, že není záměrem banky spolehnout se při predikci finanční bonity pouze na klasifikaci navrženou diskriminační funkcí.

I v takových případech je možné výsledků diskriminační analýzy použít. MDA může totiž zároveň sloužit jako nástroj identifikace proměnných, které mezi zvolenými skupinami rozlišují nejlépe. Takto identifikované proměnné mohou přispět ke stanovení indikátorů, na které se mají analytické úvěrového oddělení zaměřit při posuzování jednotlivých žádostí o úvěr.<sup>86</sup>

Po identifikaci důležitých proměnných diskriminační analýzou v takových případech následuje klasická finanční analýza na individuální bázi. Cílem této práce není podrobně vyložit vztahy týkající se podnikových financí. Do této podkapitoly proto nezařazuji ilustraci obecných postupů tak, jak jsem provedla v pasáži pojednávající o využití MDA přímo pro predikci. Způsob, jakým je dle mého názoru možné využít výsledků MDA v případech, ve kterých není možné či žádoucí okamžitě funkci aplikovat na nová pozorování, je zřejmý z diskuse interpretací výsledků analýz, uvedených v kapitole páté.


---

<sup>85</sup> S takovým omezením jsem se potýkala i v rámci příkladu aplikace diskriminační funkce, uvedeném v páté kapitole.

<sup>86</sup> Příspěvek jednotlivých proměnných k diskriminaci a procento variability závisle proměnné, které je pomocí zvolené kombinace proměnných vysvětleno, je přirozeně nutné posuzovat z hlediska výsledků testů statistické významnosti. Pro výklad viz např. McLachlan (1992), Afifi a Clark (1990) nebo Altman (1968).

### 3.3. Závěr

Cílem třetí kapitoly bylo naznačit na teoretické rovině rozměr prostoru, který systemizaci měření úvěrového rizika přináší metoda vícerozměrné diskriminační analýzy. Na nástin obecných možností zohlednění specifických požadavků na systém posuzování bonity, zahrnutý v kapitole třetí, bych v rámci kapitoly čtvrté ráda navázala shrnutím směru předchozího výzkumu na toto téma. V následující kapitole uvádím rovněž zamyšlení nad otázkou, jejíž zodpovězení považuji pro zmapování možností využití výsledků aplikace MDA ve finanční analýze za klíčové: Jedná se o otázku možnosti vytvoření „univerzální funkce“, vhodné pro predikci finanční situace kdekoli v prostoru a čase. S použitím výsledků předchozích studií, citovaných v rámci čtvrté kapitoly, vytyčím několik předpokladů vytvoření a úspěšného používání takové funkce. Příspěvek k ověření splnění identifikovaných předpokladů v případě české ekonomiky pak nabízí empirická analýza možností využití MDA pro predikci finanční tísně, prezentovaná v kapitole páté.



## 4. MDA V PŘEDCHOZÍCH EMPIRICKÝCH STUDIÍCH

V třetí kapitole jsem se pokusila vyložit teoretické základy diskriminační analýzy a naznačit dva způsoby využití jejích výsledků – predikci finanční situace a vytipování důležitých závislostí. Dále jsem se zabývala zejména možnostmi zohlednění znalostí o struktuře dat a cílech, které banka sleduje, za účelem ovlivnění diskriminační síly výsledné funkce.

Nyní mám v úmyslu navázat na předchozí výklad přiblížením a zhodnocením publikovaných výzkumných prací, v jejichž rámci již byly popsány metody využity ke klasifikaci podniků na zdravé a spějící k těžkostem a nastínit možnosti další úspěšné aplikace. Shrnu po řadě tři studie, ze kterých každou lze považovat v určitém smyslu za průkopnickou.

V rámci kapitoly páté pak přistoupím k vlastní analýze dat za české podniky pomocí metody vícerozměrné diskriminační analýzy (MDA) a k srovnání jejích výsledků s výsledky dvou ze tří prezentovaných studií.<sup>87</sup>

### 4.1. Jednorozměrná analýza dat z americké ekonomiky

První z prací, kterou bych ráda v kostce shrnula, je práce W. Beavera.<sup>88</sup> Vzhledem k jejímu prvenství v pokusu použít diskriminační analýzu pro předpověď bankrotu ji považuji za relevantní z hlediska záměru této diplomové práce, i když se rozsahem využití závěrů nepochybně nevyrovná výsledkům, kterých dosáhly obě dále uvedené studie. Základem Beaverovy analýzy byla myšlenka, že podnik je zásobníkem likvidních aktiv. Tento zásobník je doplňován přílivem a odčerpáván odlivem likvidního majetku na základě zisků, respektive ztrát z provozní činnosti.<sup>89</sup> Pokud je odliv soustavně větší než příliv, likvidní aktiva budou ze zásobníku zcela vyčerpána a podnik se ocitne ve finanční tísní. Beaver vyšel při konstrukci modelu z následujících předpokladů:

- větší objem zásobníku snižuje pravděpodobnost úpadku;
- čím vyšší je objem čistého přílivu likvidních aktiv generovaných provozní činností, tím nižší je pravděpodobnost úpadku;
- větší objem dluhu zvyšuje pravděpodobnost finančních těžkostí firmy;
- vyšší výdaje na zajištění provozní činnosti zvyšují pravděpodobnost úpadku.

Závěrem Beaverovy studie bylo zjištění, že proměnnou, která samostatně nejlépe vysvětluje sklon firmy k úpadku, je poměrový ukazatel peněžní tok/celkový dluh.

---

<sup>87</sup> Jako referenci použiji pouze studie, které byly provedeny na základě MDA, tedy Altman (1968) a Buchtíková (1998).

<sup>88</sup> Viz Beaver (1966) cit. v Sjovoll (1999).

<sup>89</sup> Viz Sjovoll (1999).

Podle studie Keaseyho a Watsona<sup>90</sup> postrádá Beaverova práce technickou formulaci modelu a neobsahuje návrh vážení jednotlivých společně působících efektů. Jejím jediným příspěvkem k teorii je potvrzení skutečnosti, že společnost bude vystavena bankrotu, pokud jí dojdou likvidní aktiva. I když Beaver modeloval finanční zdraví firmy zjednodušeně pouze jako funkci množství likvidních aktiv, domnívám se, že předznamenal metodologický posun ve zkoumání užití statistických metod ve finanční analýze. Použitím jednorozměrné diskriminační analýzy dal Beaver impuls dalším autorům, aby se začali zabývat statistickým modelováním závislosti platební schopnosti firem na finančních ukazatelích a jejich interakcích.

## 4.2. Vícerozměrná analýza dat z americké ekonomiky

První z významných vědeckých prací, které se ubíraly naznačených směrem a zkoumaly aplikaci MDA na predikci finanční situace firem, je známá studie E. I. Altmana, publikovaná v roce 1968.<sup>91</sup> Cílem jeho studie bylo zjistit, zda mohly být poměrové ukazatele spočtené na základě dat z účetních výkazů firem za léta 1946-1965 použity k predikci bankrotu firem.

### 4.2.1. Motivace analýzy

Altmanovou motivací ke zkoumání uvedené závislosti byla skutečnost, že pozoroval, jak „akademikové směřují k eliminaci používání analýzy poměrových ukazatelů jako metody zhodnocení výkonnosti firem“.<sup>92</sup> V době vzniku práce bylo použití poměrových ukazatelů z finančních výkazů v analytické praxi chápáno spíše jako příklon k tzv. odhadům od oka<sup>93</sup> než aplikace teorií podložených postupů. Altman si položil otázku, zda je tento náhled na poměrové ukazatele oprávněný, nebo zda je možné překlenout propast mezi analýzou poměrových ukazatelů, používanou v praxi, a přesnějšími metodami statistiky, oblíbenými v řadách akademiků.<sup>94</sup>

Hlavní přínos předchozích studií závislosti stavu firmy na finančních datech z předešlých let<sup>95</sup> viděl autor zejména v tom, že poskytly důležitá zobecnění týkající se velikosti a trendů určitých ukazatelů. Za nedostatek však považoval Altman skutečnost, že dosavadní studie ukazovaly na významnost vždy jednoho ze tří ukazatelů: ziskovost, likvidita, solventnost. Ze závěrů studií však nebylo zřejmé, jaká je relativní významnost ukazatelů, neboť každá ze studií uvedla jiný konkrétní ukazatel. Altman komentoval omezení úspěšného použití výsledků studií v praxi následovně: Uvedl jednoduchý příklad firmy, která vykazuje nízkou ziskovost, po případě i solventnost. Metody doporučující jako měřítko jeden z těchto ukazatelů by ukázaly na tendenci firmy k úpadku. Pokud by

<sup>90</sup> Keasey, Watson cit. v Sjovoll (1999).

<sup>91</sup> Viz Altman (1968).

<sup>92</sup> Volný překlad z Altman (1968), s. 589.

<sup>93</sup> Lze říci, že ve smyslu členění přístupů k ohodnocování bonity klientů uvedeném v první kapitole byly metody analýzy pomocí poměrových ukazatelů řazeny spíše mezi metody tradičního přístupu.

<sup>94</sup> Altman (1968).

<sup>95</sup> Altman vedle Beaverovy práce uvádí např. Smith, Winakor (1935), Hickman (1958).

však podnik vykazoval nadprůměrnou likviditu, mohl by závazkům dostát za použití svých likvidních aktiv. Situace by pro něj nebyla zdaleka tak nepříznivá, jak předpověděly metody zaměřené na ziskovost, respektive solventnost.

Altman proto navrhl „...rozšíření zmíněných studií použitím metody umožňující kombinovat různé faktory a vytvořit smysluplný model schopný predikce“.<sup>96</sup> Metodou, vhodnou k identifikaci ukazatelů důležitých pro posouzení zdraví firmy a k nastavení vah vybraných indikátorů podle jejich relativního vlivu, je právě vícerozměrná diskriminační analýza.<sup>97</sup>

#### 4.2.2. Výběr dat a průběh analýzy

Pro identifikaci ukazatelů s významným vlivem na finanční situaci firem použil Altman vzorek 66 podniků z výrobní sféry, ve kterém byly rovným dílem zastoupeny podniky prosperující i podniky, jejichž činnost ukončil bankrot. Altman zdůraznil, že složení vzorku zkrachovalých podniků bylo dáno omezenou dostupností dat za tyto firmy, a že se v důsledku toho jednalo o skupinu poměrně heterogenní.<sup>98</sup> Autor proto sestavil vzorek prosperujících podniků tak, aby každý v něm zahrnutý subjekt odpovídal velikostí a odvětvovou specifikací jednomu ze subjektů ze vzorku zkrachovalých podniků. Vstupem Altmanovy analýzy bylo 22 finančních ukazatelů, které považoval za potenciálně významné pro vysvětlení nadcházejícího bankrotu, respektive prosperity. Výběr ukazatelů, jejichž společná schopnost předpovědi bankrotu firmy je nejvyšší ze všech posuzovaných kombinací vstupů, provedl Altman na základě analýzy, jejíž klíčovou část tvoří dvě činnosti:

- i) pozorování statistické významnosti parametrů různých funkcí, pozorování relativního příspěvku každé nezávisle proměnné;
- ii) zkoumání klasifikační schopnosti vybrané funkce.

Obsah těchto kroků odpovídá dvěma způsobům využití diskriminační analýzy v bankovníctví, které jsem popsala v podkapitole 3.2.

#### 4.2.3. Výsledky analýzy

Diskriminační funkce, kterou Altman po provedení analýzy statistické významnosti zvolil jako nejvhodnější, má tvar:

$$Z = 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 + 0,999X_5. \quad (4.1.)$$

---

<sup>96</sup> Volný překlad z Altman (1968), s. 591.

<sup>97</sup> Teoretickým východiskům MDA a možnostem úprav jejich základních parametrů podle potřeb zkoumaného jevu je věnována podkapitola 3.1.1.

<sup>98</sup> S podobným omezením dostupnosti dat jsem se setřetla i při sběru údajů pro vlastní příklad, popsany v rámci kapitoly páté.

Kombinace proměnných, kterou Altman vybral pro vysvětlení bankrotu za nejvhodnější, tedy zahrnovala následující ukazatele:

$$X_1 = \text{pracovní kapitál} / \text{celková aktiva}$$

$$X_2 = \text{zadržené zisky} / \text{celková aktiva}$$

$$X_3 = \text{EBIT} / \text{celková aktiva}$$

$$X_4 = \text{tržní kapitalizace} / \text{účetní hodnota dluhu}$$

$$X_5 = \text{tržby} / \text{celková aktiva}$$

Uvedenou funkci, nazývanou Altmanovo Z-skóre, podrobil autor citované studie několika testům schopnosti klasifikace. V následujících odstavcích uvedu výsledky tří metod, které považuji z hlediska přispění k potvrzení významnosti zjištěné závislosti za nejdůležitější.

Pro první test použil empirickou metodu, jejíž podstata byla rozebrána již v podkapitole 3.2.1.1.1. Původní vzorek 33 podniků v každé ze skupin podrobil klasifikaci pomocí funkce, která byla vytvořena s jeho použitím. Výsledek testu empirickou metodou potvrdil očekávání vysokého procenta správných klasifikací, plynoucí z charakteru empirické metody. Model správně klasifikoval 95 % celého vzorku. Chyba typu  $\alpha$  nastala pouze v šesti procentech případů; model tedy správně klasifikoval 94 % všech nezdravých podniků. Chyba typu  $\beta$  nastala dokonce pouze ve třech procentech<sup>99</sup>.

Protože použití empirické metody, jak bylo vysvětleno v podkapitole 3.2.1.1.1, značně podhodnocuje chybovost funkce, podnikl Altman alternativní test, založený na metodě kapesního nože, vyložené v podkapitole 3.2.1.1.3. Altman nevyčlenil každé z pozorování samostatně.<sup>100</sup> Rozdělil vstupní vzorek pouze pěti různými způsoby a provedl pět analýz a pět testů. Průměrný podíl správné klasifikace dat pak činil 93,5 %.<sup>101</sup>

Posledním z testů klasifikační schopnosti funkce, jehož výsledky bych na tomto místě ráda zmínila, je test pomocí sekundárních dat. Jedná se o aplikaci zvolené funkce na nová data, která nebyla využita k diskriminační analýze, tedy o test pomocí křížové metody nastíněné v podkapitole 3.2.1.1.2. Autor testoval funkci po řadě na 25 nových podnicích, které později zbankrotovaly, a na 66 zdravých firmách. Výsledkem bylo zjištění čtyřprocentního výskytu chyby  $\alpha$  a jednadvacetiprocentního výskytu chyby  $\beta$ .<sup>102</sup>

Pokud vyjdeme z předpokladu dostatečné reprezentativnosti vzorku sekundárních dat, je možné říci, že jeho model je vhodnější k předpovídání bankrotu než pro predikci prosperity. Z hlediska věřitele je pravděpodobně funkce s takovými výsledky příznivější než funkce vykazující

<sup>99</sup> Zdroj údajů: Altman (1968), s. 599.

<sup>100</sup> Jak bylo zmíněno, je metoda kapesního nože ve své původní podobě časově velmi náročná.

<sup>101</sup> Podrobnější popis postupu je možné nalézt na s. 601 citované publikace.

<sup>102</sup> Klasifikační matice těchto testů jsou na s. 601, respektive 602 citované studie.

opačnou relaci chyb. Jak totiž bylo uvažováno v sub-kapitole 3.2.1.2.2., bývají náklady chyby  $\alpha$  oproti nákladům chyby  $\beta$  významnější.<sup>103</sup>

Altman vedle testů, jejichž výsledky jsem prezentovala výše, provedl také validaci funkce pomocí historických dat. Uvedená metoda je založena na aplikaci funkce na starší data o podnicích, které byly obsaženy v primárním vzorku. Použití informace o klasifikační schopnosti získané touto cestou k validaci zvolené funkce však de facto předpokládá, že koeficienty jednotlivých vstupních proměnných jsou v čase konstantní. Nesplnění tohoto předpokladu, v praxi zpochybnitelného, by oslabilo nejen výsledky validace funkce historickou metodou, ale i možnost volné přenositelnosti funkce v čase. O ověření tohoto poměrně důležitého předpokladu, který v rámci Altmanovy analýzy nebyl testován, jsem se pokusila v rámci vlastního příkladu, který prezentuji v kapitole páté.

Při odhlédnutí od uvedeného problému s testem historickou metodou lze říci, že se Altmanovi podařilo poukázat na statisticky významnou závislost úpadku podniku na poměrových ukazatelích za předchozí období. Splnil tak svůj úkol vytyčený v úvodu studie, totiž podložit v praxi využívané postupy statistickou analýzou.

Altman se nespokojil s obhájením přínosu analýzy poměrových ukazatelů. Chtěl dát analytikům poměrových ukazatelů – úvěrovým manažerům, investorům apod. – univerzální nástroj použitelný pro predikci platební schopnosti i bez počítačového vybavení.<sup>104</sup> Proto hledal odhad dělícího bodu oboru hodnot.<sup>105</sup>

Při hledání kritické hodnoty využil výsledků výše popsaného testování klasifikační schopnosti zvolené funkce pomocí empirické metody. Z dosahovaných hodnot funkce  $Z$  bylo patrné, že všechny podniky, jejichž data generovala hodnoty  $Z$  nižší než 1,81, šly k bankrotu a byly do této skupiny vybranou funkcí skutečně přiřazeny. Prosperující podniky, které vykazovaly hodnoty  $Z$  vyšší než 2,99,<sup>106</sup> byly zařazeny do skupiny prosperujících. V intervalu  $\langle 1,81; 2,99 \rangle$  funkce vykazovala chybné klasifikace. Klasifikace nového podniku, jehož skóre by padlo do tohoto intervalu nazývaného šedá zóna,<sup>107</sup> by nebyla možná. Altman proto rozdělil šedou zónu na několik disjunktních intervalů a pozoroval, kolik chybných klasifikací funkce vykazuje v každém z nich. Při porovnání zjistil, že nejméně chyb generovala funkce v intervalu  $\langle 2,67; 2,68 \rangle$ . Za nejlepší kritickou hodnotu, aproximující bod průniku křivek zachycujících hustotu pozorování generujících různé hodnoty  $Z$ , proto označil střed tohoto intervalu, bod, kde  $Z = 2,675$ .

---

<sup>103</sup> Jak však bude vidět v závěru ke kapitole páté, je možné při aplikaci Altmanovy funkce na české podniky pozorovat vychýlení tímto směrem v míře, jaká podrývá význam Altmanem vypořádaného vztahu v českých podmínkách.

<sup>104</sup> Otázkou možnosti nalezení univerzální funkce vysvětlující finanční situaci firem kdekoli v čase a prostoru se zabývám v podkapitole 4.3. Prakticky jsem se tuto možnost pokusila otestovat v rámci analýz uvedených v kapitole páté.

<sup>105</sup> Též je používán termín „kritická hodnota“.

<sup>106</sup> Viz s. 606 citované studie.

<sup>107</sup> V originále „zone of ignorance“ nebo „gray area“.

Altmanova studie pomohla nalézt teoretické zdůvodnění oprávněnosti použití poměrových ukazatelů pro predikci finančního zdraví podniků. Při použití typologie přístupů k posuzování bonity klientů popsané v první kapitole této práce lze říci, že se Altmanovi podařilo přenést analýzu poměrových ukazatelů z metod tradičního přístupu mezi postupy přístupu nového.

V době, kdy programové vybavení umožňující vytváření vlastních modelů finanční situace nebylo tak rozšířené jako dnes, byla podle mého názoru legitimní i Altmanova snaha nalézt „univerzální funkci“, kterou by mohli používat široké kruhy finančních analytiků. V průběhu používání Altmanovy funkce však bylo nalezeno velké množství případů, nesledujících vztahy shrnuté v původním modelu.<sup>108</sup> Univerzálnost původního modelu tím byla zpochybněna a funkce se stala předmětem různých úprav.<sup>109</sup>

### 4.3. Hranice přenositelnosti modelů

Výsledky Altmanova výzkumu jsou dodnes nápomocny finančním analytikům celého světa při predikci finanční situace podniků. Dosažitelnost Altmanova cíle vytvořit univerzální model<sup>110</sup> finanční tísně se však ukázala jako přinejmenším problematická. V následujících pasážích se pokusím nastínit základní překážky vytvoření univerzálního modelu.

#### 4.3.1. Rozdílné podmínky v různých ekonomikách

Hlavním předmětem diskusí o vhodnosti použití Altmanova skóre ve finanční analýze je otázka, zda může být funkce vytvořená na základě dat za podniky jedné ekonomiky úspěšně použita pro predikci finanční situace podniků jiných zemí. Hypotézu, že odlišné ekonomické prostředí může generovat jiné váhy ukazatelů ve funkci, vysvětlující diskriminaci mezi firmami podle finančního zdraví, považuji z hlediska cíle této práce za relevantní nejen ve vztahu k Altmanově funkci, ale i na obecné rovině. Její platnost může být podle mého názoru dobře posouzena až po porovnání výsledků modelů zachycujících strukturu vnějšího prostředí s výsledky referenčních funkcí, vytvořených na základě dat prostředí vnitřního. Ukázkou takového srovnání nabízí podkapitola 5.4, v jejímž rámci je vedle sebe postaven výsledek aplikace Altmanovy metody, výsledek studie Buchtíkové (1998) a funkce zvolené na základě analýzy dat za české firmy v rámci této práce.

Některé argumenty proti prostému přenosu funkce z ekonomiky na ekonomiku jsou nasnadě i bez podobného experimentálního zkoumání. Např. Alena Buchtíková<sup>111</sup> zmiňuje v případě Altmanova skóre rozdílnou vypovídací schopnost ukazatele tržní hodnota vlastního jmění ve vyspělé americké ekonomice a v tuzemsku. Vzhledem k tomu, že tuzemský kapitálový trh má nesporně nižší likviditu než kapitálový trh v USA, a neodráží tak očekávání trhu, je pravděpodobné, že poměr tržní

<sup>108</sup> V českých podmínkách např. Brynda (2000).

<sup>109</sup> I sám Altman vytvořil řadu modifikací původního modelu: např. Z skóre pro nevýrobní podniky, pro neobchodovatelné firmy, ZETA, popsané např. v Altman, Caouette, Narayan (1998).

<sup>110</sup> Respektive soubor modelů (viz pozn. 109).



hodnota vlastního jmění/účetní hodnota dluhu bude pro mnohé firmy vychýlený a nebude přispívat ke správné diskriminaci firem.

#### 4.3.2. Definice kritéria diskriminace

Další vlastnost, která může odradit potenciálního uživatele Altmanovy funkce a jí podobných modelů, je její schopnost rozlišení pouze do dvou skupin.<sup>112</sup> Pro účely posuzování bonity bankovních klientů je vhodnější rozlišení jemnější, kopírující jejich stávající strukturu. Může se jednat například o potřebu rozlišení do tří skupin:

- klienti s předpokládanou perfektní platební disciplínou;<sup>113</sup>
- dlužníci, jejichž splácení bude třeba kontrolovat, po případě úvěr zajistit větším objemem kolaterálu;<sup>114</sup>
- úvěry, jejichž poskytnutí by generovalo nedobytnou pohledávku.<sup>115</sup>

Použití modelu rozlišujícího mezi dvěma typy klientů by v takovém případě mohlo mít například následující dopady: Pokud by pomohlo vyčlenit ztrátové pohledávky, nepřineslo by v důsledku jediné hranice mezi skupinami rozlišení mezi prvními dvěma skupinami uchazečů. Na základě výsledků takového modelu by nebylo možné poskytnout klientům s perfektní platební disciplínou výhodnější podmínky v podobě nižšího úroku (plynoucího z nižší rizikové prémie), nižšího objemu kolaterálu apod. V konkurenčním prostředí by vysoce bonitní klienti čerpali úvěr u jiné banky. Riziko portfolia banky, která použila metodu s hrubším rozlišením, by tak vzrostlo.

Jiný možný scénář by nastal v případě, že by model byl vychýlen opačným směrem.<sup>116</sup> Jeho použití by pak přinášelo pouze vyčlenění vysoce bonitních uchazečů. Pokud by banka na základě takového rozlišení přidělovala úvěry, přicházela by o úrokové výnosy z úvěrů, které by v případě schopnosti jemnějšího rozlišení bylo možné ocenit vyšší rizikovou premií.

#### 4.4. Vícerozměrná analýza dat z české ekonomiky

Zmíněné důvody možné nevhodnosti přímého použití Altmanova Z-skóre, plynoucí jak z různého významu ukazatelů, tak z potřeby jiného typu rozlišení mezi firmami, jsou impulsem k modifikacím původního Z-skóre. Ráda bych na tomto místě upozornila na výzkumnou práci

---

<sup>111</sup> Viz Buchtíková (1998).

<sup>112</sup> Specifika definice kritéria diskriminace mohou být podle mého názoru obecnou překážkou přenositelnosti funkcí (viz např. diskusi analytických nevýhod kritéria diskriminace zvoleného pro příklad uvedený v páté kapitole – podkapitola 5.2.1.1.)

<sup>113</sup> Standardní úvěry.

<sup>114</sup> Ex post by takové úvěry patřily mezi sledované, nestandardní či pochybné úvěry.

<sup>115</sup> Ztrátové úvěry.

<sup>116</sup> Tedy směrem k vyššímu procentu chyby typu  $\beta$ .

Buchtíkové (1998),<sup>117</sup> která zkoumá závislost bonity tuzemských klientů bank na jejich předchozích finančních výsledcích.

Hlavním cílem prvních fází projektu, v jehož rámci výzkumná studie proběhla, bylo vypracovávat každoročně pro úvěrová oddělení bank přehled průměrných podílových ukazatelů za jednotlivá odvětví. Další součástí výzkumné studie Aleny Buchtíkové byla analýza závislosti platební disciplíny klientů zúčastněných bank na hodnotách poměrových finančních ukazatelů. Autorka zvolila pro rozlišení mezi podniky metodu diskriminační analýzy a pokusila se, podobně jako Altman, vytvořit funkci vysvětlující rozdíly mezi úvěrovanými subjekty v celé ekonomice. Nejprve použila analýzu binární volby,<sup>118</sup> jejímž výsledkem byla následující funkce:

$$D = -0,460 + 0,019 * X_1 + 0,026 * X_2 - 0,028 * X_3 - 0,015 * X_4 + 0,020 * X_5 - 0,018 * X_6 - 0,023 * X_7 - 0,010 * X_8 - 0,301 * X_9 + 0,015 * X_{10} + 0,003 * X_{11}, \quad (4.2.)$$

kde :

$X_1$  = hmotný investiční majetek / aktiva;

$X_2$  = dlouhodobé pohledávky / aktiva;

$X_3$  = rezervy / pasiva;

$X_4$  = dlouhodobé závazky / pasiva;

$X_5$  = krátkodobé závazky / pasiva;

$X_6$  = tržby za prodej zboží a výkony / výnosy celkem;

$X_7$  = odpisy nehmotného a hmotného investičního majetku / výnosy celkem;

$X_8$  = rentabilita výnosů;

$X_9$  = využití aktiv;

$X_{10}$  = celková zadluženost;

$X_{11}$  = doba splatnosti dluhů.<sup>119</sup>

Tato funkce při aplikaci empirické metody vykazovala 83,81 % správné klasifikace. Vykazovala však poměrně širokou šedou zónu.<sup>120</sup> V dalším byla proto analýza rozšířena a bylo použito rozlišení

<sup>117</sup> Studie byla provedena v rámci projektu „Finanční hodnocení bonity bankovních klientů“, který vznikl v roce 1995 jako společná iniciativa Institutu ekonomie České národní banky a některých bankovních subjektů působících v tuzemsku.

<sup>118</sup> Modely diskriminující pouze do dvou skupin bývají nazývány „modely binární volby“, pojem „modely multinomické volby“ je pak používán pro modelování klasifikace do více než dvou skupin.

<sup>119</sup> Viz s. 24 citované studie.

<sup>120</sup> Velikost šedé zóny je vidět z grafu rozdělení výsledných hodnot diskriminační funkce v příloze k citované studii. Viz Buchtíková (1998), s. 55.

do třech skupin podniků podle platební schopnosti. Výsledkem byla funkce, jejíž testování empirickou metodou ukázalo na pouhých 66,19 % správné klasifikace.<sup>121</sup>

Použití modelu multinomické volby bylo umožněno detailností informací o platební schopnosti klientů, které autorka v rámci projektu obdržela od zúčastněných bank. Z důvodů utajení bankovních informací znemožňují smluvní podmínky související s popsáním projektem<sup>122</sup> publikování použitých dat. Z hlediska jemnosti klasifikace se proto jedná o studii unikátní. Na její výsledky může navázat dalším zkoumáním opět pouze samotná autorka,<sup>123</sup> další autor neoperující v rámci ČNB může navazující studii podniknout až po zavedení centrálního registru klientských informací.<sup>124</sup>

Studie Aleny Buchtíkové nepochybně přispěla k utvoření obrazu o struktuře klientů českého bankovního sektoru jako celku. Nalezení statisticky významných závislostí mezi poměrovými ukazateli a finanční bonitou klientů v podmínkách české ekonomiky představuje nepochybně důležitý impuls k přechodu finančních institucí k tvorbě modelů posuzování bonity klientů.

Ráda bych však zmínila, že zdroje pochybností o možnostech vytvoření univerzálního modelu finanční tísně, které jsem uvedla v předchozí podkapitole, mohou být aktuální i v tomto případě. Autorka pracovala s vědomím omezené možnosti využití Altmanova modelu v českých podmínkách. Pokusila se tento problém řešit tak, že sledovala strukturu dat za subjekty úvěrované bankami působícími na území ČR, které byly ochotny zúčastnit se projektu. Domnívám se však, že používání takto získané funkce k měření úvěrového rizika v praxi je bez průběžných aktualizací na základě změn ve struktuře klientů, nákladů, strategie či preferencí dané banky zpochybnitelné. Argument, který může vést k takovému zpochybnění, se zakládá na hypotéze, že prostředí, ve kterém podniky operují, se liší nejen v prostoru, ale i v čase. K ověření této hypotézy se pokusím přispět pomocí aplikace funkce, kterou vytvořila Buchtíková (1998) na základě dat za roky 1993-1997, na data za roky 1998-2001. Výsledné hodnoty jednotlivých typů chyb pak srovnám s výsledky klasifikace pomocí funkce, vytvořené v tomto pozdějším období.

## 4.5. Závěr

V kapitole čtvrté jsem se pokusila shrnout směr dosavadního výzkumu využití MDA v analýze finanční bonity. Nastínila jsem i potenciální problémy, které mohou nastat při přenosu výsledných funkcí. Jak jsem uvedla, byli si oba výše jmenovaní autoři vědomi prostorové dimenze tohoto problému a pokoušeli se ho ošetřit: Altman se pokusil problém s různými charakteristikami prostředí, ve kterém se podniky pohybují, řešit například úpravami původního modelu pro firmy neobchodované

<sup>121</sup> Tvar funkce je uveden na s. 25 citované studie.

<sup>122</sup> Shrnutí smluvních podmínek autorka uvádí na s. 9-10 citované studie.

<sup>123</sup> Použití dat pro studie je limitováno i v rámci ČNB, autorka má tedy v určitém smyslu slova na podobné studie monopol. Na uvedenou studii navázala v následujícím roce studii Buchtíková (1999), v jejímž rámci se zabývala ekonomickou interpretací modelu.

<sup>124</sup> O zavedení registru pojednává podkapitola 2.2.3.1.

na kapitálovém trhu či pro podniky nevýrobní. Buchtíková řešila případ omezené možnosti využití modelů přinesených z vnějšku do České republiky. Skutečnost, že funkce, které byly výsledkem výše uvedených studií, při porovnání vykazují značné odlišnosti,<sup>125</sup> nedovoluje vyvrátit hypotézu o tom, že koeficienty modelů různých prostředí jsou odlišné.

Pokud by byl jediným rozměrem problému přenositelnosti aspekt prostoru, bylo by možné situaci řešit vytvořením modelu pro každou specifickou oblast. Vytvoření univerzálního diskriminačního modelu, byť jen pro určitou oblast, je však dále komplikováno faktorem času. Protože se ekonomická prostředí přirozeně vyvíjejí, může se obecně měnit i podoba modelu, který v daném čase nejlépe vystihuje charakteristické rysy jednotlivých skupin podniků. Modely vytvořené v rámci studií podobných těm, které jsem citovala, tak mohou podle mého názoru bankám sloužit spíše jako zdroj inspirace při tvorbě vlastních modelů či pro porovnání dosažené klasifikační schopnosti.

Dalším zajímavým aspektem, jehož význam byl ve výše uvedených studiích podceňen, je postupnost vývoje finanční situace jednotlivých podniků.<sup>126</sup> V souvislosti s touto vlastností lze očekávat stírání některých rozdílů mezi podniky jednotlivých skupin směrem dále do minulosti a nerovnost koeficientů příslušných jednotlivým proměnným při analýze různých časových okamžiků.<sup>127</sup>

V následující kapitole budu prezentovat příklad, v jehož rámci jsem se pokusila odhalit míru, do jaké výše jsou uvažované jevy pozorovatelné v české ekonomice. Nalezení diskriminačních funkcí rozlišujících mezi skupinami při různé časové struktuře nezávisle proměnných umožní pozorovat význam vývoje jednotlivých charakteristik a oprávněnosti obav z nepřenositelnosti modelů v čase. Srovnání klasifikační schopnosti, kterou vykázal Altmanův model při aplikaci na data za české podniky, s diskriminační silou modelu vytvořeného v rámci této práce pak přispěje k posouzení vlivu přenosu modelů v prostoru.

Ráda bych zdůraznila, že jsem si s ohledem na očekávání přítomnosti výše uvedených charakteristik nekladla za cíl vytvořit funkci s širokou využitelností v bankovní praxi. Snažila jsem se spíše odhalit, zda je česká ekonomika prostředím, jehož charakteristiky lze popsat pomocí statistických metod. Domnívám se, že dosažené výsledky pomohou odhalit potenciál zvýšení efektivity úvěrování, který českým bankám nabízí systemizace pomocí MDA.

---

<sup>125</sup> Viz tvar funkcí uvedený výše, po případě tvary modelů po úpravách v Altman, Caouette a Narayan (1998).

<sup>126</sup> Podnik není založen jako podnik v konkursu. Ne všechny podniky, které nesplácejí úvěr, byly založeny za účelem získání úvěru a jeho nesplacení.

<sup>127</sup> Pokud by byl takový vývoj potvrzen, byl by podryt význam testu klasifikační schopnosti modelu pomocí historických dat, zmíněný v pasáži pojednávající o Altmanově výzkumu.

## 5. EMPIRICKÁ STUDIE FINANČNÍ SITUACE ČESKÝCH PODNIKŮ

V předchozích pasážích jsem se pokusila zhodnotit přínosy dosavadních studií aplikace statistiky na klasifikaci podniků, které, jak jsem zmínila, spočívají zejména v poukázání na existenci závislosti finanční situace na datech z předchozích finančních výkazů. V následujících podkapitolách bych na tyto studie ráda navázala a pokusila se navrhnout způsob, kterým je možné zkoumat vývoj a změny uvedených závislostí a vytvářet vlastní modely, vyhovující struktuře klientů v daném období.

Hlavním cílem příkladu, jehož výsledky budu v následujících pasážích interpretovat, bylo zjistit, zda lze pomocí MDA identifikovat proměnné, vysvětlující nejlépe diskriminaci českých podniků do skupin podle finanční situace. Sestavení vstupních vzorků pro jednotlivé analýzy bylo podřízeno dalšímu cíli, který spočíval v ověření vhodnosti předpokladu neměnnosti funkce v čase. Konečně srovnání výsledků testů klasifikační schopnosti, zařazené na závěr kapitoly, jsem provedla s cílem přispět ke zjištění míry omezení přenositelnosti v čase i prostoru.

### 5.1. Popis příkladu

Prvním krokem analýzy bylo přirozeně rozhodnutí, jaké kritérium bude bráno jako vysvětlovaná proměnná, respektive jak budou definovány jednotlivé skupiny. Vysvětlením a zdůvodněním volby členění podniků podle vyhlášení konkursu, respektive hladké prosperity, se zabývám v podkapitole 5.2.1.

Následně bylo nutné vybrat vhodné vysvětlující proměnné. Jejich výběr probíhal ve dvou krocích. V první fázi jsem se snažila nashromáždit co nejvíce ukazatelů, jejichž vliv na hodnotu vysvětlované proměnné jsem pokládala za obecně možný. V této fázi jsem se řídila na jedné straně informacemi získanými ze studia předchozích analýz, provedených jak v rámci tradičního, tak v rámci nového přístupu k posuzování bonity klientů, respektive finančního zdraví podniků obecně,<sup>128</sup> na straně druhé pak dostupností dat. Proměnné, které jsem v této fázi zvolila jako možné vstupy, popíši v podkapitole 5.2.2. V rámci téhož oddílu se budu věnovat rovněž krátké diskusi možných vlivů jednotlivých proměnných.

Další fáze výběru vysvětlujících proměnných již proběhla v rámci vlastní diskriminační analýzy a její výsledek se odvinul od výsledků testů statistické významnosti vlivu jednotlivých kombinací proměnných.

---

<sup>128</sup> Především Altman (1968), Buchtíková (1998), Sekerka (1998)

## 5.2. Výběr proměnných a následné úpravy

### 5.2.1. Výběr kritéria diskriminace

Kritériem pro definici skupin v případě bank je přirozeně reálné splácení úvěru. Skutečné hodnoty, kterých tato proměnná nabývá, jsou však známy jen bance, která má mezi svými aktivy pozorovaný úvěr. Informace o tom, že některý podnik nedodržel splátkový kalendář, nejsou pravidelně zveřejňovány. Pro studijní účely proto bývají až na výjimky<sup>129</sup> nedostupné.

Alternativou členění podniků na klienty, které splácejí úvěr, a na ty, které mají se splácením různě závažné potíže, a východiskem z výše popsané situace, je použití poněkud hrubšího rozlišení na podniky, které prosperují a naopak ty, na které byl vyhlášen konkurs. Jedná se o proxy členění, které se opírá o úvahu, že podnik, na který je vyhlášen konkurs, není schopen splácet úvěr.

Jak již jsem zmínila, jde ve srovnání se členěním vhodným pro analýzy v bankovní praxi o členění méně jemné, podklady pro analýzu na něm založenou jsou však veřejně dostupné: Informaci o tom, na které podniky byl vyhlášen konkurs, je možné nalézt v Obchodním věstníku, jako měřítko dobré prosperity lze použít například umístění na předních místech žebříčků prosperujících podniků.

#### 5.2.1.1. Diskuse vhodnosti zvoleného kritéria diskriminace

Použití kritéria vyhlášení konkursu jako aproximace veřejně nedostupné proměnné nesplácení úvěru, v sobě skrývá analytické nevýhody, na které bych nyní ráda upozornila.

Existuje řada podniků, na které konkurs vyhlášen nebyl, a přesto bankám způsobují nedostatečnou platební disciplínou těžkosti. Poskytování úvěrů na základě diskriminační funkce vytvořené s použitím mnou zvoleného aproximativního členění by proto z tohoto hlediska mohlo vykazovat velké procento chyby  $\alpha$ .<sup>130</sup>

Pokud je úvěr dobře zajištěn kolaterálem, je pravděpodobnost uspokojení pohledávky v rámci konkursního řízení zvýšena. Předpoklad, že podnik, na který byl vyhlášen konkurs, může v analýze zastupovat podnik, jejíž úvěr je pochybný či ztrátový, tedy může být zavádějící i v opačném směru. Použití funkce s vysvětlovanou proměnnou vyhlášení konkursu pro klasifikaci bankovních klientů tedy může přinést vychýlení i co do velikosti chyby  $\beta$ .<sup>131</sup>

V souvislosti s popsaným omezením vyvolaným použitým kritériem členění do skupin předesílám, že si tato práce neklade za cíl vytvořit funkci, aplikovatelnou na posuzování bonity klientů v bankovní praxi. Je spíše zaměřena na hledání odpovědi na otázku, zda je vůbec možné při posuzování finančního zdraví firem v českých podmínkách metody nového přístupu použít. Výsledky modelování předpovědi finanční situace pomocí kritéria vyhlášení konkursu v rámci této

<sup>129</sup> Např. Buchtíková (1998), rozebraná v podkapitole 4.4 této práce, nebo Sjøvoll (1999).

<sup>130</sup> Definice chyby typu  $\alpha$  viz tabulka 1.

práce proto mohou být dle mého názoru impulsem pro další testování napozorovaných závislostí na datech, která jsou k tomuto účelu vhodnější.

### 5.2.2. Výběr nezávisle proměnných

Volbu vstupů do modelu jsem přizpůsobila cíli ověření předpokladu neměnnosti modelu v čase. Uvažovala jsem důležitý aspekt, zmíněný již Eisenbeisem.<sup>132</sup> Většina autorů studií, zaměřených na předpovídání finanční situace či bonity podnikových klientů,<sup>133</sup> modeluje závislost výsledného stavu pomocí hodnot ukazatelů odpovídajících pouze jednomu období před pozorováním stavu. Ukazatele za období dále před pozorováním pak autoři často používají jako data pro testování klasifikační schopnosti modelu.<sup>134</sup> Implicitně tak předpokládají, že koeficienty proměnných za jedno období před pozorováním stavu firmy jsou shodné s koeficienty, jaké by byly výsledkem analýzy proměnných za předchozí období ( $b_i = b_{i,2} = b_{i,3} = \dots = b_{i,n}$ ).<sup>135</sup> Pokusila jsem se vhodnost tohoto předpokladu ověřit provedením tří různých analýz proměnných za zpožděná období. První analýza zkoumá vliv ukazatelů za období bezprostředně před pozorovaným stavem firmy. V rámci druhé analýzy jsem se pokusila nalézt indikátory nebezpečí uzavření smluvního vztahu s podnikem, který spěje ke konkursu, s předstihem. Samozřejmě by bylo příhodné zkoumat období několik period do minulosti. Vzhledem k nedostatku dostupných delších časových řad u podniků v konkursu jsem se však musela spokojit s analýzou období dva roky před jeho vyhlášením. V rámci třetí analýzy jsem dala prostor pro srovnání příspěvků jednotlivých proměnných mezi oběma obdobími. Cílem bylo nalézt případné vztahy mezi ukazateli za jednotlivá období, a podat tak ucelenější závěr o vlivech působících na konkurs.

V první fázi výběru proměnných jsem shromáždila celkem 18 proměnných. Zaměřila jsem se výhradně na poměrové ukazatele, neboť alespoň do určité míry eliminují vliv rozdílů ve velikosti firem, zastoupených ve vzorku. V podkapitole 5.2.2.1 shrnu obsah jednotlivých proměnných a zdůvodnění očekávání, že by mohly být nápomocny při vysvětlování příčin finanční situace firmy, respektive její predikci. Popisem vzorku firem, z jejichž finančních výkazů byly hodnoty zvolených ukazatelů vypočteny, se budu zabývat v oddílu 5.2.3.

#### 5.2.2.1. Zvolené vstupy a diskuse jejich očekávaného vlivu

V následující pasáži se zaměřím na ekonomický výklad jednotlivých ukazatelů, jejichž vliv bude posuzován v rámci analýz. Vyslovím v ní předpokládané působení jednotlivých indikátorů

---

<sup>131</sup> Definici chyby typu  $\beta$  shrnuje tabulka 1.

<sup>132</sup> Eisenbeis (1977) uvažuje dopad volby časové struktury vstupů zejména v souvislosti s měnicími se apriorními pravděpodobnostmi.

<sup>133</sup> Např. Altman (1968), Sinkey (1975) nebo Buchtíková (1998).

<sup>134</sup> Viz popsany test pomocí historických dat, provedený Altmanem.

<sup>135</sup> Zde je  $n$  počet předcházejících období, za která jsou data k testování klasifikační schopnosti modelu používána.

na diskriminaci a nastíním jejich provázanost, pramenící ze skutečnosti, že zdrojem jejich výpočtů jsou vzájemně provázané položky finančních výkazů.

Shromáždila jsem hodnoty všech níže uvedených proměnných za dvě období. Kromě očekávaných vlivů jednotlivých proměnných a závislostí mezi nimi, které uvádím v každém z následujících odstavců, je proto možné předpokládat vysokou míru korelace mezi jednotlivými proměnnými posunutými o období.<sup>136</sup>

#### 5.2.2.1.1. Ukazatele likvidity

Ukazatele likvidity mají obecně tvar podílu „čím je možno platit / co je nutno platit“.<sup>137</sup> Při použití každého z ukazatelů k vysvětlení finanční situace by bylo možné očekávat, že vyšší hodnoty generují spíše příslušnost do skupiny prosperujících podniků.

Různé formy výpočtu likvidity de facto pouze různě ošetřují skutečnost, že jednotlivé složky oběžných aktiv mají odlišnou likvidnost a že se některé z nich pohybují na rozhraní oběžných a stálých aktiv. V důsledku společných zdrojů výpočtu je tedy možné předpokládat, že budou mezi sebou silně korelovány. Ještě před provedením analýzy je proto možné očekávat, že zahrnutí jednoho z ukazatelů likvidity do vícerozměrného modelu bude provázeno redundancí ostatních.

Ráda bych na tomto místě dále zdůraznila, že ukazatele likvidity by pravděpodobně vykazovaly větší diskriminační sílu v modelu, rozlišujícím na základě skutečné platební disciplíny (např. vůči bance), než v analýze, v jejímž rámci jsou pozorování členěna do skupin konkurs a prosperita. Likvidita je totiž, jak zdůrazňuje Sekerka (1998), měřítkem schopnosti plynule uhrazovat běžné závazky a v jejich rámci krátkodobé bankovní úvěry a splátky dlouhodobých půjček. Podnik, který vykazuje nízké stupně likvidity, tedy nebude (pokud je referenční hodnota likvidity správně zvolena) pravděpodobně schopen dostát svým krátkodobým závazkům v termínu jejich splatnosti. Takový podnik je při rozlišení podle schopnosti reálného splácení bance zařazen do skupiny klientů s nižší bonitou. Naopak v členění, jaké používám v této práci, může podnik se sub-optimální likviditou obecně patřit do skupiny označené prosperita. V důsledku toho pak může být výsledkem analýz provedených v rámci této práce zjištění, že hodnoty těchto ukazatelů k diskriminaci velkou měrou nepřispívají.

<sup>136</sup> Skutečně pozorované korelace jsou uvedeny v Příloze II a diskutovány v podkapitole 5.2.4.2.2.

<sup>137</sup> Výjimkou je ukazatel poměru pracovního kapitálu – viz níže. I u něj však platí, že je počítán ze stejných údajů jako ostatní ukazatele zahrnuté do této skupiny.



### Poměr pracovního kapitálu ( $X_1$ )

Prvním z ukazatelů, který podrobím testům diskriminační analýzy, je poměr pracovního kapitálu. Jedná se o podíl:

$$X_1 = PK/A,$$

kde PK je pracovní kapitál a A jsou aktiva celkem, přičemž pracovní kapitál je definován následovně:

$$PK = OA - KZ,$$

kde OA jsou oběžná aktiva a KZ jsou krátkodobé závazky. Použití ukazatele PK v poměru k A zachycuje objem likvidních prostředků ve vztahu k velikosti podniku. Záporné hodnoty tohoto ukazatele<sup>138</sup> vypovídají o nevyvážené struktuře financování – o financování některých stálých aktiv z krátkodobých zdrojů. To poukazuje na možné problémy se splácením krátkodobých závazků a nebezpečí ohrožení vztahů s věřiteli. Naopak příliš vysoké hodnoty  $X_1$  mohou signalizovat špatné využití likvidních prostředků, generující vysoké náklady příležitosti jejich držby.

### Běžná likvidita ( $X_2$ )

Ukazatel běžné likvidity dává informaci o míře, jakou jsou krátkodobá pasiva kryta oběžnými aktivy. Obdržíme jej z podílu

$$X_2 = OA/KZ,$$

kde OA jsou opět oběžná aktiva a KZ krátkodobé závazky. Pokud nabývá ukazatel  $X_2$  hodnoty 1, nachází se podnik v situaci, kdy množství oběžného majetku právě vystačí na krytí krátkodobých závazků. Taková hodnota běžné likvidity je však považována za velmi rizikovou, neboť může ohrozit splácení bankovních půjček<sup>139</sup>. Ještě rizikovější je situace, kdy podnik používá část krátkodobých závazků jako zdroj financování stálých aktiv. V takovém případě je  $X_2$  dokonce menší než 1 a oběžná aktiva v dané chvíli nestačí ani na pokrytí krátkodobých závazků.<sup>140</sup>

---

<sup>138</sup> Přirozeně i záporné hodnoty PK.

<sup>139</sup> Viz. např. Sekerka (1998)

<sup>140</sup> Taková situace odpovídá záporným hodnotám pracovního kapitálu (viz předchozí bod).

### Pohotová likvidita ( $X_3$ )

Měřítkem likvidity podniku, které je přísnější než likvidita běžná, je likvidita pohotová. Je poměrem

$$X_3 = (OA - Z)/KZ,$$

kde OA jsou oběžná aktiva, Z jsou zásoby, a KZ opět krátkodobé závazky. Odečtení zásob od oběžných aktiv je ošetřením skutečností, že se jedná o nejméně likvidní formu oběžných aktiv a že není vždy jednoduché je použít pro plynulé plnění krátkodobých závazků.

### Okamžitá likvidita ( $X_4$ )

Okamžitá likvidita je ve finanční analýze považována za ještě tvrdší měřítko než ukazatele  $X_2$  a  $X_3$  popsané výše, neboť oproti  $X_3$  odečítá z čitatele krátkodobé pohledávky a měřítkem likvidity je z jeho hlediska pouze finanční majetek:

$$X_4 = FM/KZ,$$

kde FM je finanční majetek a KZ krátkodobé závazky. U společností, které nejsou schopny přimět své odběratele ke splácení závazků z obchodního styku v dostatečně krátké lhůtě, je možné pozorovat vysoké průběžné stavy krátkodobých pohledávek a tedy poměrně velký rozdíl mezi ukazateli  $X_3$  a  $X_4$ .

#### 5.2.2.1.2. Ukazatele rentability a ziskovosti

Do další skupiny ukazatelů jsem zařadila indikátory vyjadřující schopnost společnosti generovat zisky z aktiv, respektive tržeb. V čitateli je tedy vždy nějaký ukazatel odpovídající hospodářskému výsledku (toková veličina), ve jmenovateli pak údaj zachycující nějaký druh kapitálu (stavová veličina), respektive tržeb (toková veličina). Při použití stavové veličiny ve vzorci se ve finanční analýze používá buď její hodnota k určitému datu, nebo aritmetický průměr počáteční a koncové hodnoty.<sup>141, 142</sup>

Protože jsou ukazatele sestaveny tak, aby vyjadřovaly schopnost společnosti využít svých aktiv, respektive tržeb, k vytváření zisků, lze očekávat, že přiřazení firmy do skupiny „prosperita“ bude na každém z ukazatelů, které jsem zařadila do této skupiny, pozitivně závislé. Teprve pomocí vícerozměrné analýzy však lze ověřit, jak k diskriminaci do skupin přispívají všechny společně.

---

<sup>141</sup> Viz Sekerka (1998).

<sup>142</sup> Při výpočtech ukazatelů pro příklad jsem použila hodnoty stavových veličin k datu účetní závěrky.

### Kumulativní ziskovost ( $X_5$ )

Kumulativní ziskovost společnosti můžeme spočítat jako podíl nerozdělených zisků na celkových aktivech:

$$X_5 = NZ/A,$$

kde NZ jsou nerozdělené zisky minulých let, A jsou celková aktiva.

Jak zdůrazňuje Altman (1968), jedná se o ukazatel, který implicitně uvažuje i dobu trvání společnosti: Mladý podnik bude pravděpodobně ve srovnání s podniky operujícími na trhu déle ceteris paribus vykazovat nižší hodnotu ukazatele  $X_5$ , protože u ní bude v čitateli zahrnut součet zisků kumulovaných po kratší dobu. Lze tedy říci, že pokud by byl tento ukazatel na základě diskriminační síly příslušné funkce zvolen pro diskriminaci, byly by mladší firmy diskriminovány oproti starším, byla by jim přiřazována vyšší aposteriorní pravděpodobnost úpadku než déle činným firmám se srovnatelnými hodnotami ostatních parametrů. Altman proto považoval za přínosné doplnit analýzu vlivu tohoto ukazatele na bankrot analýzou doby, po jakou před jeho vyhlášením firmy operovaly na trhu.

V době vzniku Altmanovy práce byl výsledek, kterého při zkoumání časové struktury firem dosáhl, jistě přínosný.<sup>143</sup> Altman za jeho pomoci podpořil oprávněnost uvedeného očekávání. Domnívám se však, že údaje o délce trvání jednotlivých firem před úpadkem mají v dnešní globalizované ekonomice zcela jiný obsah než v době, kdy Altman publikoval uvedenou úvahu. Soudím totiž, že datum založení dceřiných společností nadnárodních koncernů ve zkoumané zemi není jednoduše srovnatelné s datem založení národních společností. V české ekonomice je navíc obsah data založení společností dále zamlžen skutečností, že mnohé společnosti jsou právními nástupci státních podniků, které existovaly již dávno před datem založení těchto společností uvedeným v Obchodním rejstříku.

Protože nepokládám výsledky takové analýzy pro případ současné české ekonomiky za průkazné, rozhodla jsem se od ní upustit a omezit se pouze na upozornění na možnost výskytu závislosti, kterou Altman pro případ americké ekonomiky v šedesátých letech potvrdil.

### Využití celkových aktiv ( $X_6$ )

Tento ukazatel, spočtený jako podíl

$$X_6 = T/A,$$

---

<sup>143</sup> Altman na základě dat publikovaných společností Dun & Bradstreet zjistil, že z firem, které v roce 1965 prodělaly bankrot, bylo předtím 50 % na trhu méně než 5 let a 31 % méně než 3 roky. Viz citovaná studie, s. 595.

kde T jsou tržby a A jsou opět celková aktiva, je standardním finančním ukazatelem, ilustrujícím schopnost firmy využít celkových aktiv k vytváření tržeb.<sup>144</sup>

#### Rentabilita vlastního jmění ( $X_7$ )

Rentabilita vlastního jmění má tvar:

$$X_7 = HVC/VJ,$$

kde HVC je hospodářský výsledek po zdanění a VJ je vlastní jmění společnosti. Ukazatel  $X_7$  má zásadní význam pro vlastníky společnosti, neboť měří ziskovost vloženého kapitálu. Měl by nabývat vyšších hodnot než výnos z bezrizikových cenných papírů, a nabízet tak rizikovou prémii.

Pro věřitele má tento ukazatel podpůrný význam. Míra, do jaké podnik zhodnocuje vlastní kapitál, přináší i informaci o možné míře zhodnocení kapitálu cizího.

#### Rentabilita výnosů ( $X_8$ )

Stupeň rentability výnosů neboli schopnost firmy vytvářet zisky z výnosů, můžeme sledovat z podílu:

$$X_8 = HVC/VC,$$

kde HVC je hospodářský výsledek po zdanění a VC jsou výnosy celkem. U společností, které generují hospodářskou ztrátu, bude tento ukazatel nabývat záporných hodnot. Protože právě vytváření hospodářských ztrát může být primární příčinou platební neschopnosti, lze očekávat, že záporné hodnoty tohoto ukazatele budou znamenat zařazení firmy do skupiny podniků ve finanční tísní.<sup>145</sup>

#### Podíl přidané hodnoty na tržbách a výkonech ( $X_9$ )

Ukazatel je dán podílem:

$$X_9 = PH/TAV,$$

kde PH je přidaná hodnota, T jsou tržby za zboží a prodej vlastních výrobků a služeb, a měří schopnost podniku vytvářet přidanou hodnotu v rámci provozní činnosti.

---

<sup>144</sup> Ve finanční analýze bývá často posuzován ukazatel ROA, definovaný jako podíl hospodářského výsledku a aktiv. Vzhledem k tomu, že tento ukazatel vykazuje vysokou míru korelace s ukazatelem ROE ( $X_7$ ), rozhodla jsem se namísto něho použít ukazatel  $X_6$ , tak jak je definován v textu.

<sup>145</sup> Pro analýzy provedené v rámci této práce pak zařazení do skupiny podniků v konkurzu.

### Provozní zisková marže ( $X_{10}$ )

Provozní zisková marže, spočtená jako:

$$X_{10} = PHV/T,$$

kde PHV je provozní hospodářský výsledek a T jsou tržby za zboží a prodej vlastních výrobků a služeb, měří schopnost firmy generovat z tržeb provozní zisky a dává tak implicitně do vztahu tržby firmy s náklady vynaloženými při jejich vytváření.

#### 5.2.2.1.3. Ukazatele aktivity<sup>146</sup>

Ukazatele aktivity pomáhají posoudit schopnost společnosti využívat vložených prostředků tím, že měří jejich vázanost v jednotlivých druzích aktiv nebo pasiv. Tyto ukazatele jsou ve finanční analýze konstruovány ve dvou podobách: mohou vyjadřovat počet obrátek jednotlivých složek zdrojů nebo majetku během časového intervalu nebo reciprokou hodnotu - dobu obratu některé z položek aktiv či pasiv ve dnech. Obecně lze říci, že dlouhé doby obratu aktiv<sup>147</sup> signalizují jejich špatné využití a nízkou efektivnost firmy. Dlouhé doby obratu pasiv jsou pak signálem platební neschopnosti.

### Doba obratu pohledávek ( $X_{11}$ )

Doba obratu pohledávek byla pro účely této práce spočtena na základě podílu:

$$X_{11} = KP/(PV/360),$$

kde KP jsou krátkodobé pohledávky k datu účetní závěrky a PV/360 jsou průměrné denní provozní výnosy.

Ukazatel  $X_{11}$  vyjadřuje průměrnou dobu, po kterou firmě její odběratelé zůstávají dlužní, tedy průměrný počet dní, který uplyne mezi prodejem na úvěr a přijetím peněz. Příliš vysoké hodnoty tohoto ukazatele mohou ukazovat na nebezpečí druhotné platební neschopnosti. Obecně lze tedy očekávat pozitivní závislost aposteriorní pravděpodobnosti finanční tísně firmy na hodnotě ukazatele  $X_{11}$ .<sup>148</sup>

---

<sup>146</sup> Do skupiny ukazatelů aktivity patří vedle indikátorů  $X_{11} - X_{14}$  z hlediska konstrukce i ukazatel *doba splatnosti dluhů*. V popisovaném příkladu jsem ho však zkoumala v souvislosti se skupinou ukazatelů, popisujících zadluženost firmy. Jeho popis proto zařazuji až v bodě 5.2.2.1.4.

<sup>147</sup> Respektive nízký počet obrátek za dané období.

<sup>148</sup> Pro odhalení nebezpečí druhotné platební neschopnosti by bylo přínosné zkoumat podíl nedobytných pohledávek. Tento údaj však pro všechny zkoumané podniky nebyl k dispozici.

Doba obratu aktiv ( $X_{12}$ )

Doba obratu aktiv je dána podílem

$$X_{12} = A/(HVC + O),$$

kde A jsou aktiva celkem, HVC je hospodářský výsledek po zdanění a O jsou odpisy.

Indikátor označený pro účely této práce  $X_{12}$  vyjadřuje, jak dlouho podnik potřebuje k tomu, aby z peněžního toku<sup>149</sup> obnovil svá celková aktiva. Nižší hodnoty ukazatele naznačují příliš malou finanční flexibilitu firmy.

Doba splatnosti závazků ( $X_{13}$ )

Tento ukazatel je protějškem ukazatele  $X_{11}$  – spočteme ho s použitím vzorce

$$X_{13} = KZ/(PN/360),$$

kde KZ jsou krátkodobé závazky a PN/360 jsou průměrné denní provozní náklady.

Vyjadřuje, kolik dní v průměru uběhne mezi nákupem zboží, materiálu či služeb a úhradou částky, odpovídající jeho ceně. V praxi řízení finančních prostředků firmy<sup>150</sup> může být cílem dosahování takové hodnoty ukazatele  $X_{13}$ , která by převyšovala ukazatel  $X_{11}$ . Průměrná doba splatnosti krátkodobých závazků, která převyšuje průměrnou dobu splatnosti krátkodobých pohledávek, pozitivně ovlivňuje hotovostní zůstatky společnosti. Příliš dlouhé doby splatnosti závazků, ať jsou způsobeny prvotní či druhotnou platební neschopností, však vedou k vysokému objemu závazků po splatnosti a k hrozbě podání návrhu na vyhlášení konkursu. Je tedy pravděpodobné, že ukazatel  $X_{13}$  by v jednorozměrné analýze ovlivňoval pravděpodobnost konkursu.

Doba obratu zásob ( $X_{14}$ )

Ukazatel „doba obratu zásob“ je používán k získání odhadu časového intervalu, po který je podnik schopen pokračovat v provozní činnosti bez další dodávky zásob.<sup>151</sup> Je spočten jako podíl

$$X_{14} = Z/(PN/360),$$

kde Z jsou zásoby ke dni účetní závěrky a PN/360 jsou průměrné denní provozní náklady.

---

<sup>149</sup> Součet hospodářského výsledku a odpisů (HV + O) aproximativně nahrazuje ukazatel volného peněžního toku. Volný peněžní tok, vyjadřující finanční flexibilitu společnosti, je určen tak, že je od provozního peněžního toku odečtena částka vynaložená na obnovovací investice, dividendy a úroky. Protože však u mnoha společností nebyly k dispozici všechny údaje nutné k určení volného peněžního toku, byl použit součet HV + O.

<sup>150</sup> Cash Management.

Hodnoty tohoto ukazatele nelze dle mého názoru posuzovat bez ohledu na skutečnost, že nárůst objemu zásob nad nutnou míru zvyšuje vázanost peněz podniku.

#### 5.2.2.1.4. Ukazatele zadluženosti

Poslední skupina indikátorů, použitých jako vstupy do diskriminační analýzy, se týká zadluženosti firem. Zahrnuje dva standardní ukazatele zadluženosti, tedy ukazatele zadluženosti definované poměrem složky závazků k určitému druhu kapitálu ( $X_{15}$  a  $X_{17}$ ), dále pak jeden ukazatel, standardně zahrnovaný spíše mezi ukazatele aktivity ( $X_{16}$ ). Navíc jsem tuto skupinu ukazatelů obohatila o indikátor zachycující aktiva, která podnik použil k zajištění dlužnicko-věřitelského vztahu ( $X_{18}$ ).

Ukazatele související se zadlužením společnosti, respektive s lhůtami splácení dluhů, sehrají bezpochyby při vytipování určujících faktorů vyhlášení konkursu významnou roli.

Identifikace nebonitní firmy teprve na základě těchto ukazatelů však může přijít příliš pozdě. Použití diskriminační funkce, která by vysvětlovala finanční zdraví firmy pouze pomocí ukazatelů zadluženosti, by v bankovní praxi pravděpodobně nevedlo k příliš úspěšnému předcházení uzavírání kontraktů s nebonitními podniky. Zaměření se pouze na tyto ukazatele by totiž pravděpodobně napomohlo pouze eliminaci krajně nebonitních dlužníků.

Protože však krize rozvahová (pozorovatelná z poměrů zadluženosti) skrze propojení finančních výkazů tvoří spolu s krizí výsledkovou (signalizovanou ukazateli rentability a aktivity) a krizí cash-flow (zahrnující likviditní problémy) nepřeseknutelný cyklus,<sup>152</sup> lze očekávat, že bude zkoumání ukazatelů zadluženosti pro zjištění společného příspěvku všech ukazatelů k finančnímu zdraví firmy přínosné.

#### Celková zadluženost ( $X_{15}$ )

Celková zadluženost je definována jako podíl:

$$X_{15} = (CZ + OP)/A,$$

kde CZ jsou cizí zdroje, OP jsou ostatní pasiva a A jsou celková aktiva, a dává tak obraz o celkové struktuře financování společnosti.

#### Doba splatnosti dluhů ( $X_{16}$ )

Doba splatnosti dluhů, jak již bylo zmíněno, bývá řazena mezi ukazatele aktivity. Jak je vidět z výpočetního vzorce, je svou konstrukcí analogická ukazateli doby obratu aktiv ( $X_{12}$  – viz výše):

<sup>151</sup> Hodnoty tohoto ukazatele se budou výrazně lišit pro podniky s různým sortimentem, respektive činností.

<sup>152</sup> Toto propojení trefně shrnul náměstek ministra financí Ing. Zelinka v úvodu semináře Konkurs cestou revitalizace, organizovaném 14. ledna 2001 na IES FSV UK.

$$X_{16} = (CZ + OP)/(HVC + O),$$

kde CZ jsou cizí zdroje, OP jsou opět ostatní pasiva, HVC je hospodářský výsledek po zdanění a O jsou Odpisy. Protože se však domnívám, že lze dobu splatnosti dluhů z hlediska včasnosti identifikace problémů řadit spíše mezi ukazatele zadluženosti, umístila jsem ji až do této sekce. Doba splácení dluhů dává informaci o tom, jak dlouho podnik potřebuje k tomu, aby z peněžního toku, který je schopen generovat, uhradil veškeré své skutečné i potenciální závazky.

#### Míra zadluženosti ( $X_{17}$ )

Ukazatel míry zadluženosti je definován vztahem

$$X_{17} = (Z + Pu)/A,$$

kde Z jsou krátkodobé i dlouhodobé závazky, P jsou půjčky a A jsou celková aktiva. Jedná se o modifikaci ukazatele  $X_{15}$  s tím, že nejsou uvažovány rezervy a ostatní pasiva.

#### Zatíženost hmotného investičního majetku ( $X_{18}$ )

Do analýzy jsem se rozhodla zahrnout i ukazatel, jehož použití není obsahem standardní finanční analýzy. Jeho hodnota je dána podílem:

$$X_{18} = HIMzp/HIM,$$

kde HIMzp je hmotný investiční majetek zatížený zástavním právem a HIM je celkový hmotný investiční majetek.

Jedná se o ukazatel, spočtený na základě informace o součtu zastaveného hmotného investičního majetku a objemu HIM uvedeného v rozvaze. Je zřejmé, že je tento poměr úzce spjat se zadlužeností podniku, respektive s objemem zajištěných závazků.

Pro posuzování hodnot tohoto ukazatele pro jednotlivé firmy je podstatné, že smysluplné hodnoty se pohybují v intervalu (0;1). Hodnota větší než jedna<sup>153</sup> může být pro analytika varovným signálem netransparentní politiky podstupování závazků nebo manipulace s výkazy.

### **5.2.3. Výběr vzorku**

Sběr primárních dat, použitých pro vlastní analýzu, i dat sekundárních, na jejichž základě jsem model testovala, jsem provedla v souladu se zvoleným kritériem členění podniků do skupin<sup>154</sup> a s ohledem na dostupnost proměnných, jejichž vliv jsem se rozhodla zkoumat.<sup>155</sup>

<sup>153</sup> Taková hodnota byla v některých případech firem v konkursu skutečně pozorována.

<sup>154</sup> Popis uvádím v podkapitole 5.2.1.



Do skupiny podniků, reprezentujících firmy ve finanční tísní (skupina 1), jsem zařadila firmy, které splňovaly obě následující podmínky:

- byl na ně v letech 1998-2000 vyhlášen konkurs;<sup>156</sup>
- jejich finanční výkazy byly veřejně dostupné.<sup>157</sup>

Uvedení druhé ze zmíněných podmínek je zdánlivě zbytečné, chtěla bych jím však podtrhnout skutečnost, že finanční výkazy firem, na něž byl vyhlášen konkurs, ve velkém množství případů nejsou dostupné, v jiných případech pak zdaleka nejsou úplné. Vzhledem k tomu, že jsem chtěla zkoumat vliv proměnných za ty roky před konkursem, které by byly mezi podniky srovnatelné, byla jsem při sběru dat odkázána na pečlivé prohledávání databází firem. Způsob shromažďování dat byl proto časově velmi náročný. Nicméně se mi podařilo nasbírat potřebná data o 40 výrobních, stavebních a obchodních firmách za období roku a dvou let před vyhlášením konkursu.

Protože nebyla tato skupina podniků vzhledem k popsanému způsobu sběru dat homogenní, rozhodla jsem se v rámci možností přizpůsobit sběr dat reprezentující skupinu prosperujících podniků (skupina 2). Nasbírala jsem výkazy 64 firem, odpovídajících přibližně oborem činnosti firmám ve skupině 1.

V rámci rozdělení dat na primární a sekundární data jsem učinila odhad poměru apriorních pravděpodobností, jehož případné změny by pochopitelně měly vliv na výsledky analýzy. Jak jsem již zmínila v podkapitole 3.2.1.2.1., je v případě bank možné tento údaj aproximovat poměrem výskytu bonitních a nebonitních dlužníků banky. Pro analýzu, provedenou v rámci této práce, jsem se rozhodla aproximovat poměr obou skupin v celkové populaci na základě dat o poměru klasifikovaných úvěrů za celý bankovní sektor. Na základě agregovaných údajů zveřejněných ČNB jsem odhadla poměr skupin 1 a 2 na 3:7.<sup>158</sup> Z celkového počtu 104 výkazů jsem proto vyčlenila část tak, aby poměr obou skupin ve vzorku použitým pro analýzu<sup>159</sup> odpovídal tomuto odhadu.

#### 5.2.4. Diskuse struktury dat a její úpravy

Již před provedením analýzy musím upozornit na některé vlastnosti nasbíraných dat, na které je třeba brát ohled při interpretaci výsledků.

---

<sup>155</sup> Viz pasáž 5.2.2.

<sup>156</sup> Období 4 roků bylo zvoleno z důvodů neexistence dostupných dat za období kratší.

<sup>157</sup> Finanční výkazy jsem vyhledávala zejména pomocí serveru [www.securities.com](http://www.securities.com).

<sup>158</sup> Podle informací zveřejněných Odborem bankovního dohledu na [www.stránkách ČNB](http://www.stránkách ČNB) byl objem klasifikovaných úvěrů za celý bankovní sektor k 31. 3. 2000 vyčíslen na 244 miliard Kč, což tvoří 28,3 % podíl v objemu úvěrů celkem, k 30. 6. 2000 se jednalo o 243,9 miliard Kč (28,5 % celkových úvěrů), k 30. 9. 2000 pak 243,3 miliard (28,1 %).

<sup>159</sup> Pro odhad diskriminační funkce byl vytvořen vzorek obsahující 21 firem skupiny 1 a 48 firem skupiny 2. Zbývající data byla použita pro testování klasifikační schopnosti funkce křížovou metodou.

#### 5.2.4.1. Rozdíly ve velikosti firem

Mezi vzorky je možné pozorovat velké rozdíly co do velikosti měřené objemem aktiv.<sup>160</sup> Jelikož však v tuzemsku neexistuje zdroj dat, který by obsahoval dostatečně velké množství v členění podle finanční situace a umožňoval tak výběr homogenních vzorků pro studijní účely,<sup>161</sup> rozhodla jsem se analýzu provést na datech sebraných popsáním způsobem i přes možné limity použití závěrů. Pro dosažení částečné eliminace předpokládaných negativních efektů rozdílné velikosti jsem pro analýzu použila výhradně poměrové ukazatele.

#### 5.2.4.2. Diskuse předpokladů aplikace MDA

Výsledky aplikace diskriminační analýzy a možnosti její interpretace jsou do velké míry ovlivněny strukturou dat, která jsou k analýze použita. Zastávím se proto nyní u vlastností souboru dat, použitých pro vytvoření analýzy, a upozorním na ty charakteristiky vzorku, které by mohly mít vliv na vypovídací schopnost diskriminační funkce.

##### 5.2.4.2.1. Náhodnost výběru a normalita rozdělení

První dva předpoklady dobré vypovídací schopnosti výsledného modelu, uvedené v podkapitole 3.1.1. pod čísly i), respektive ii), jsou předpoklady náhodnosti výběru vzorku a normality rozdělení vysvětlujících proměnných. Splnění prvního z předpokladů bylo nastíněno již v podkapitole 5.2.3.: Jak již bylo řečeno, byl sběr dat podřízen zejména dostupnosti jednotlivých údajů. Shromážděné výkazy jsem rozdělila následujícím způsobem: Na základě odhadu apriorních pravděpodobností jsem náhodně vybrala množství podniků obou skupin pro tvorbu analýzy, a to tak, aby odpovídala odhadnutému poměru.<sup>162</sup> Zbývající podniky, které již bohužel neodpovídaly zvolenému poměru apriorních pravděpodobností,<sup>163</sup> tvořily sekundární data pro validaci.

Předpoklad ii) byl v důsledku omezení náhodnosti výběru a v důsledku způsobu konstrukce některých proměnných<sup>164</sup> splněn jen u některých vstupních proměnných. Problémové jsou, jak je vidět z většiny grafů rozdělení proměnných uvedených v příloze VI, zejména hodnoty proměnných za

---

<sup>160</sup> Průměrný objem aktiv za firmy ve skupině 1 je cca 900 milionů Kč, ve skupině 2 je asi desetkrát vyšší.

<sup>161</sup> Takový souhrn představuje např. databáze firem sestavená s použitím dat poskytnutých přímo bankami, který použila k analýze A. Buchtíková (1998). Ten je však vzhledem ke smluvním podmínkám zmíněným v subkapitole 4.4 této práce k dalším analýzám nepoužitelný.

<sup>162</sup> 48 prosperujících podniků, 21 podniků v konkursu přibližně odpovídá přibližně odhadnutému poměru 30% nebonitních firem.

<sup>163</sup> Jak je vidět z výsledků testování klasifikačních schopností výsledných funkcí, byl poměr apriorních pravděpodobností u sekundárních dat ve prospěch podniků v konkursu. Proto jsem při výpočtu celkové chyby klasifikace vážila jednotlivé typy chyb tak, abych poměr apriorních pravděpodobností alespoň simulovala.

<sup>164</sup> Viz podkapitola 5.2.2.1.

skupinu podniků v konkursu. Předpoklad normálního rozdělení splnily původně u obou skupin pouze proměnné  $X_1, X_2, X_6, X_{14}, X_{1\_2}, X_{2\_2}, X_{3\_2}, X_{6\_2}, X_{14\_2}$ .<sup>165</sup>

Nesplnění předpokladu normality rozdělení proměnných neznemožňuje samo o sobě použitelnost dat pro analýzu<sup>166</sup>, ale omezuje možnost použití testů dalších předpokladů<sup>167</sup>. Proto se ošetřením tohoto jevu budu zabývat až v souvislosti s testováním dalších předpokladů dobré vypovídací schopnosti testů statistické významnosti.

#### 5.2.4.2.2. Korelace mezi proměnnými

Vzhledem k tomu, že jsou vstupní proměnné, patřící do stejné skupiny ukazatelů,<sup>168</sup> vždy počítány z hodnot, které mají více či méně společný základ, je možné u nich očekávat vysokou míru korelace. Ráda bych upozornila na skutečnost, že na rozdíl od regresní analýzy není u diskriminační analýzy existence korelace mezi vstupními proměnnými porušením předpokladů jejího úspěšného použití.<sup>169</sup> Proměnná korelovaná s jinou vstupní proměnnou přináší v diskriminační analýze malý dodatečný příspěvek k diskriminaci a její zahrnutí do modelu je více či méně zbytečné.<sup>170</sup>

Očekávání existence korelace mezi proměnnými z každé ze čtyř skupin, jehož zdůvodnění jsem uvedla výše v podkapitole 5.2.2.1., bylo v případě shromážděných dat u některých proměnných potvrzeno.<sup>171</sup> Silná korelace je pozorovatelná mezi proměnnými  $X_2$  a  $X_3$  (0,919767) a  $X_3$  a  $X_4$  (0,793135). Jedná se o tři ukazatele likvidity (běžná, pohotová a okamžitá). Vzhledem k metodě jejich výpočtu<sup>172</sup> bylo možné jejich vzájemnou provázanost očekávat. V souladu s očekáváním je rovněž silná korelace napozorovaná mezi ukazateli likvidity  $X_{2\_2}$  a  $X_{3\_2}$ . V analýze, ve které se tyto proměnné vyskytnou zároveň, lze očekávat poměrně velkou redundanci (nízkou hodnotu tolerance) ukazatele pohotové likvidity, která vykazuje silnou korelaci s oběma ostatními ukazateli.

Poměrně silná závislost je pozorovatelná i mezi proměnnými  $X_8$  (rentabilita výnosů) a  $X_{10}$  (provozní zisková marže). Oba ukazatele popisují schopnost firmy generovat zisky z výnosů. Ukazatel  $X_8$  je poněkud obecnější.<sup>173</sup>

Dále je možné pozorovat vysokou hodnotu korelace (0,991409) mezi proměnnými obratu aktiv ( $X_{12}$ ) a doby splatnosti dluhů ( $X_{16}$ ). U obou proměnných je ve jmenovateli obsažen člen volného finančního toku, liší se pouze zahrnutím či nezahrnutím hodnoty vlastního jmění ve jmenovateli.<sup>174</sup>

---

<sup>165</sup> Index  $i\_2$  zde značí proměnnou zpožděnou o dvě období. Indexem  $i$  jsou opatřeny proměnné zpožděné pouze o jedno období.

<sup>166</sup> Viz výklad předpokladů v podkapitole 3.1.1.

<sup>167</sup> Např. Boxova M-testu testujícího hypotézu, že proměnné v obou skupinách sledují stejné rozdělení. (Viz níže.)

<sup>168</sup> Jedná se o čtyři skupiny ukazatelů: likvidita, rentabilita, aktivita a zadluženost. Vymezení skupin ukazatelů a definice jednotlivých proměnných je obsahem podkapitoly 5.2.2.1.

<sup>169</sup> Viz Eisenbeis (1977).

<sup>170</sup> Existence korelace mezi vstupními proměnnými je však nebezpečná v případě, že je natolik silná, že nelze provést inverzi kovarianční matice. Tímto případem se zabývám v podkapitole 5.2.4.2.3.

<sup>171</sup> Korelace mezi proměnnými jsou uvedeny v příloze II.

<sup>172</sup> Viz podkapitola 5.2.2.1.

<sup>173</sup> Definice ukazatelů viz podkapitola 5.2.2.1.2.

Další dvojici proměnných, mezi nimiž byla naměřena relativně vysoká korelace (0,992056), tvoří proměnné míry zadluženosti ( $X_{15}$ ) a celkové zadluženosti ( $X_{17}$ ) – též v souladu s očekáváním.<sup>175</sup>

U proměnných zpožděných o dvě období lze navíc pozorovat korelaci mezi proměnnými  $X_{5\_2}$  (kumulativní ziskovost) a  $X_{10\_2}$  (provozní zisková marže).

V souvislosti s časovou návazností finančních výkazů bylo možné očekávat, že jednotlivé zpožděné proměnné budou korelovány vždy v páru (proměnné  $X_i$  s proměnnými  $X_{i\_2}$ ). Vysoká míra korelace hodnot ukazatelů za období jdoucí po sobě je však pozorovatelná pouze u proměnné poměru pracovního kapitálu ( $X_1$ ), využití celkových aktiv ( $X_6$ ) a doby obratu zásob ( $X_{14}$ ). Jednou z možných interpretací nízkého počtu pozorovaných korelací mezi po sobě jdoucími zpožděnými proměnnými je celková nestabilita zkoumaného prostředí nebo existence dalších proměnných, které do modelu nebyly zahrnuty a tvoří důležitou součást činitelů, měnících pravděpodobnost konkursu skrze působení na změny ekonomické prosperity společnosti. V souvislosti s touto interpretací bych ráda upozornila na možnost rozšíření analýzy o studium vlivů, které nebyly přímo v ohnisku zájmu této práce. Zajímavé výsledky by jistě přinesla například studie významnosti vlivu struktury a růstu daného odvětví či uvalených restrikcí na pravděpodobnost konkursu.

#### 5.2.4.2.3. Shodnost kovariančních matic

Test shodnosti kovariančních matic je zaměřen na zjištění srovnatelnosti rozdělení obou skupin, a tedy i na případnou detekci rozdílných rozptylů proměnných za jednotlivé skupiny. K vyšetření shodnosti kovariančních matic je standardně používán Boxův M-test.<sup>176</sup> Provedení tohoto testu bylo však v případě původního souboru 2 x 18 proměnných znemožněno vysokou korelací mezi některými proměnnými, která znemožnila inverzi kovariančních matic.<sup>177, 178</sup> Protože je výše uvedený negativní výsledek testu shodnosti kovariančních matic varovným signálem o možné snížené vypovídací hodnotě všech testů statistické významnosti, bylo nutné problém řešit. Rozhodla jsem se proto pro úpravy množiny vstupů.

Jak uvádí např. McLachlan (1992) nebo Eisenbeis (1977), závisí volba množiny vstupů nemalou měrou na primárním cíli analýzy. Pokud je jím použití diskriminační funkce pro klasifikaci, respektive predikci příslušnosti do skupin,<sup>179</sup> je hlavním kritériem výběru kombinace proměnných míra chyb klasifikace, zjištěná při testování výsledné funkce. V takovém případě je zřejmě v zájmu analytika zahrnout do analýzy co nejvíce ukazatelů bez ohledu na jejich strukturu. Pokud je diskriminační analýza prováděna s cílem identifikace nejvýznamnějších odlišností skupin, je podle

---

<sup>174</sup> Viz definice ukazatelů v podkapitole 5.2.2.1.

<sup>175</sup> Viz podkapitola 5.2.2.1, bod 5.2.2.1.4.

<sup>176</sup> Viz podkapitola 3.1.1.

<sup>177</sup> Tento problém diskutuje např. Eisenbeis (1977).

<sup>178</sup> Ani neparametrický test Sena a Puriho (1971) nebylo v podobě nadefinované v programu Statistica na tomto souboru možné provést.

McLachlana klíčové pozorování příspěvků jednotlivých proměnných k diskriminaci, měřených pomocí testovacích statistik. Jelikož jsou testy statistické významnosti jsou při nesplnění základních předpokladů o datech vychýlené, je v případě takového primárního cíle nejdůležitější zahrnout proměnné s rozdělením splňujícím předpoklady MDA.

Protože jsem si za cíl určila prozkoumání obou uvedených možností využití výsledků diskriminační analýzy, musela jsem při výběru podmnožiny vstupů postupovat velmi obezřetně a zvažovat vyřazení či ponechání každé z proměnných z obou uvedených hledisek.

Zkoumala jsem proto důsledky různých úprav souboru dat. Nejprve jsem vyřadila všechny vstupy, které nevykazují rozdělení blízké normálnímu. Zbyly proměnné  $X_1$ ,  $X_2$ ,  $X_6$ ,  $X_{14}$ ,  $X_{1_2}$ ,  $X_{2_2}$ ,  $X_{3_2}$ ,  $X_{6_2}$ ,  $X_{14_2}$ .<sup>180</sup> Po takovém zásahu by však ve výsledném souboru nezbyla žádná proměnná zadlužení. Nebylo by tedy možné testovat vliv předlužení na konkurs. Dále by v souboru vstupních proměnných zůstalo v případě obou období pouze po jednom ukazateli rentability ( $X_6$ ), respektive aktivity ( $X_{14}$ ). Takové snížení rozsahu analýzy jsem považovala za nežádoucí.

Sáhla jsem proto k alternativním úpravám dat: Na jednotlivé proměnné jsem aplikovala transformaci s cílem změnit jejich rozdělení tak, aby bylo blíže normalitě.<sup>181</sup> Následně jsem vyřadila proměnné, které se ani přes aplikaci transformace nepřiblížily požadovanému rozdělení.<sup>182</sup>

Snížení původního počtu vstupů tak, jak jsem ho popsala v předchozím odstavci, snižuje rozsah analýz a může teoreticky vést k vynechání důležitých vstupů. Rozhodla jsem se proto doplnit zkoumání vlivů souborů proměnných, zúžených o vstupy, které po transformacích nesplnily předpoklad normality, o analýzu vlivu původního souboru 18 proměnných.<sup>183</sup> Pro možnost porovnání důsledků zúžení množiny vstupů uvádím výsledky rozšířených analýz za období odděleně v příloze III.

V rámci poslední analýzy, jejímž cílem bylo testovat působení ukazatelů za obě období současně, jsem před sebou měla škálu proměnných za dvě na sebe navazující periody. K ošetřením

<sup>179</sup> Tedy pro první z možných využití diskriminační funkce, rozebrané v podkapitole 3.2.1.

<sup>180</sup> Výsledek Boxova M-testu pro tento soubor proměnných, významný na pětiprocentní hladině, je uveden v příloze III.

<sup>181</sup> Na proměnné nabývající hodnot vyšších než 0 jsem aplikovala funkci přirozeného logaritmu, proměnné nabývající i záporných hodnot jsem podrobila transformaci pomocí následující složené funkce:

$$f(x) = 1 + \ln x \text{ pro } x > 1,$$

$$f(x) = -1 - \ln(-x) \text{ pro } x < -1,$$

$$f(x) = x \text{ pro } x \in \langle -1, 1 \rangle.$$

Výsledná složená funkce má podobný tvar jako funkce arctg. Obor hodnot funkce arctg je však omezen na interval  $(-1; 1)$ . Složenou funkci popsanou výše považuji z tohoto hlediska za vhodnější transformaci, neboť díky oboru hodnot  $(-\infty; \infty)$  umožňuje rozlišení i mezi velmi odlehlými hodnotami transformované proměnné.

<sup>182</sup> Vyřazeny byly proměnné  $X_5$ ,  $X_8$ ,  $X_9$ ,  $X_{10}$ ,  $X_{12}$ ,  $X_{16}$ ,  $X_{5_2}$ ,  $X_{7_2}$ ,  $X_{8_2}$ ,  $X_{9_2}$ ,  $X_{10_2}$ ,  $X_{12_2}$ ,  $X_{16_2}$ .

Zbývající proměnné byly zařazeny do analýz rozebraných v podkapitole 5.3.:

Analýza 1b:  $X_1$ ,  $X_2$ ,  $X_{3LT}$ ,  $X_{4L}$ ,  $X_6$ ,  $X_{7LT}$ ,  $X_{11L}$ ,  $X_{13LT}$ ,  $X_{14}$ ,  $X_{15L}$ ,  $X_{17L}$ ,  $X_{18LT}$

Analýza 2b:  $X_{1_2}$ ,  $X_{2_2}$ ,  $X_{3_2LT}$ ,  $X_{4_2L}$ ,  $X_{6_2}$ ,  $X_{11_2LT}$ ,  $X_{13_2LT}$ ,  $X_{14_2}$ ,  $X_{15_2L}$ ,  $X_{17_2L}$ ,  $X_{13_2LT}$ ,  $X_{14_2}$ ,  $X_{17_2L}$ ,  $X_{18_2LT}$

Výsledky Boxova M-testu pro tyto soubory proměnných jsou uvedeny v příloze III.

<sup>183</sup> V příloze III jsou tyto analýzy označeny jako Analýza 1a, respektive Analýza 2a.

struktury dat provedeným v rámci analýz obou období odděleně tak přibyly další úpravy, spočívající v eliminaci proměnných vykazujících vysokou korelaci s ostatními.<sup>184</sup>

Kromě transformací souboru vstupních dat zaměřených na ošetření situace, kdy nejsou splněny předpoklady aplikace lineární MDA, existují samozřejmě i další způsoby řešení. Jedním z nich je vysvětlení diskriminace pomocí kvadratické funkce. Eisenbeis ve své studii podmínek úspěchu aplikace lineární diskriminační funkce v ekonomii<sup>185</sup> rozebírá vliv porušení předpokladu shodného rozdělení obou skupin pomocí srovnání různých výsledků předchozích studií. Např. Fischer<sup>186</sup> při řešení svého dnes již klasického příkladu klasifikace kosatců do tří skupin použil lineární pravidlo diskriminace. Eisenbeis a Avery<sup>187</sup> prokázali, že i když mohla být ve zmíněném příkladu zamítnuta hypotéza o shodnosti kovariančních matic na jakékoli měřitelné hladině významnosti, použití kvadratického pravidla<sup>188</sup> při řešení stejného problému přineslo výsledky identické těm, ke kterým dospěl Fischer. Eisenbeis (1977) dále upozornil na výsledky, jichž dosáhl Altman,<sup>189</sup> když se pokusil kvadratickou funkcí znovu modelovat závislost bankrotu na poměrových ukazatelích. Byly srovnatelné s těmi, kterých dosáhl při modelování závislosti lineární funkcí.

Srovnání mnou provedených modelování závislosti finanční tísně pomocí lineární funkce s výsledky kvadratických modelů by bylo jistě zajímavým příspěvkem, obohacujícím dále mnou provedené studie dopadů zúžení množiny vstupů. Cíl této práce však spočívá především v prozkoumání míry, do jaké je možné pro posuzování finanční bonity českých podniků využít lineární funkci. V modelování pomocí kvadratické funkce vidím proto prostor pro další studium na toto téma, které může přinést závěry o relativní vhodnosti různých metod pro tuzemské prostředí.

### 5.3. Výsledné modely

Analýzu příspěvků jednotlivých nezávisle proměnných k celkové diskriminaci jsem provedla v programu Statistica v modulu Discriminant Analysis a Anova/Manova.

#### 5.3.1. Analýza 1: jeden rok před konkursem

Nejprve jsem zkoumala diskriminační sílu ukazatelů spočtených z finančních výkazů za období bezprostředně před vyhlášením konkursu.

Při použití primárních dat zobrazujících předpokládaný poměr zdravých a nezdravých firem přibližně 3:7, tedy při třicetiprocentní apriorní pravděpodobnosti příslušnosti mezi firmy

---

<sup>184</sup> Soubor zahrnutý do Analýzy 3 tak nebyl pouhou sumou souborů pozorovaných v Analýze 1b a 2b: Vyřadila jsem proměnné  $X_{3LT}$ ,  $X_{3\_2LT}$ ,  $X_{6\_2}$ ,  $X_{15}$ ,  $X_{15\_2}$ . Výsledek Boxova M-testu je uveden v příloze III.

<sup>185</sup> Eisenbeis (1977).

<sup>186</sup> Fischer (1936) cit Eisenbeis (1977).

<sup>187</sup> Eisenbeis, Avery (1972) cit. Eisenbeis (1977).

<sup>188</sup> Jeho použití bývá v případě nesplnění předpokladu shodnosti kovariančních matic doporučováno.

<sup>189</sup> Modelování lineární funkcí, které Altman provedl v roce 1968, je rozebráno v podkapitole 4.2.2.

s nadcházejícími finančními těžkostmi, jsem jako nejlepší vybrala model, vytvořený metodou dopředné krokové diskriminační analýzy.<sup>190</sup> Charakterizuje ho následující tabulka:

Discriminant Function Analysis Summary						
Step 6, N of vars in model: 6; Grouping: K_P (2 grps)						
Wilks' Lambda: ,23963 approx. F (6,62)=32,789 p< ,0000						
	Wilks' Lambda	Partial Lambda	F-remove (1,62)	p-level	Toler.	1-Toler. (R-Sqr.)
X18LT*	0,59148	0,405139	91,0339	0,00000000	0,724915	0,27508491
X13LT*	0,31219	0,767592	18,7721	0,00005493	0,697164	0,30283594
X15L*	0,27177	0,881735	8,31593	0,00539643	0,465873	0,53412706
X7LT*	0,25755	0,930408	4,63741	0,03517902	0,934373	0,0656268
X1*	0,26658	0,898901	6,97311	0,01045602	0,315216	0,68478441
X3LT	0,24795	0,966451	2,15222	0,14741816	0,410945	0,58905464

**tabulka 3** Shrnutí proměnných zahrnutých do modelu při Analýze 1

Pozn.: Vliv proměnných označených hvězdičkou je významný na pětiprocentní hladině, z rovnice vysvětlující finanční situaci firmy je tedy nelze vyloučit.

Firmy skupiny 1<sup>191</sup> jsou na základě uvedené analýzy od firem skupiny 2<sup>192</sup> v období bezprostředně předcházející sledování stavu firem nejlépe odlišeny pomocí následující kombinace ukazatelů:

- zatíženost HIM ( $X_{18LT}$ );
- doba splatnosti závazků ( $X_{13LT}$ );
- celková zadluženost ( $X_{15L}$ );
- rentabilita vlastního jmění ( $X_{7LT}$ );
- poměr pracovního kapitálu ( $X_1$ );
- pohotová likvidita ( $X_{3LT}$ ).

Diskriminační funkce vhodná k oddělení skupin podniků pomocí rozdílů v ukazatelích za období těsně před pozorováním stavu firmy má následující tvar:

$$D = -4,7065 + 2,686.X_{18LT} + 0,7658.X_{13LT} + 0,8409.X_{15L} - 0,2970.X_{7LT} + 1,9867.X_1 - 0,4657.X_{3LT}$$

<sup>190</sup> Metoda dopředné krokové MDA je založena na postupném zařazování vysvětlujících proměnných. Jako první je zařazena proměnná s nejvyšší hodnotou parciální F-statistiky, která testuje na zvolené hladině statistické významnosti dodatečný příspěvek proměnné k diskriminaci oproti všem ostatním (u první proměnné je to tedy její samostatná vypovídací schopnost). Další proměnné jsou pak postupně zařazovány na základě stejného principu až do chvíle, kdy všechny hodnoty parciální F statistiky pro ještě nezařazené proměnné jsou nižší než zvolený limit (F-to enter). Definice F-statistiky a parciální F-statistiky viz McLachlan (1992).

<sup>191</sup> Firmy, na které byl vyhlášen konkurs

<sup>192</sup> prosperující podniky

a vysvětluje 87,2 % rozdílností mezi podniky v obou vymezených skupinách.<sup>193</sup>

Hodnoty  $D < -1,16103$  poukazují na příslušnost firmy ke skupině 2, hodnoty  $D > 2,6538$  upozorňují na podobnost firmy s podniky ve skupině 1. Hodnoty  $D$  z intervalu  $<-1,16103; 2,6538 >$  nedávají jednoznačnou informaci o příslušnosti k některé ze skupin.

V následujících odstavcích se krátce zastavím u rozboru vlivu jednotlivých ukazatelů. Domnívám se totiž, že takové zamyšlení je nezbytné pro zhodnocení využitelnosti funkce k vytipování důležitých proměnných, kterým by měla být při analýze věnována zvýšená pozornost. Samostatnou vypovídací schopnost každého z ukazatelů přibližuje následující tabulka, shrnující hodnoty standardizovaných koeficientů za jednotlivé proměnné zahrnuté ve funkci:

Standardized Coefficients for Canonical Variables	
	Root 1
X18LT	1,038847804
X13LT	0,662134111
X15L	0,577806771
X7LT	-0,312972516
X1	0,64946717
X3LT	-0,327667415
Eigenval	3,17308569
Cum.Prop	1

**tabulka 4** Standardizované koeficienty plynoucí z výsledné funkce Analýzy 1

Pozn.: Standardizované koeficienty jsou koeficienty funkce transformované tak, aby vycházela z počátku.

Jak napovídá znaménko příslušející koeficientu proměnné  $X_{18LT}$  zachycující zatíženost HIM, posouvají její vyšší hodnoty pozorovaný podnik blíže k oboru hodnot  $D$  pro firmy skupiny 1.<sup>194</sup> Tento ukazatel zachycuje podíl majetku, který byl podnik nucen zatížit zástavním právem. Je podle mého názoru úzce spjat nejen s celkovou zadlužeností podniku, ale i s hodnocením jeho důvěryhodnosti v očích partnerů. Podniky, o jejichž činnosti si ostatní subjekty vytvářejí pozitivní očekávání, mohou podle mého názoru získávat půjčky zajištěné nižším objemem kolaterálu, než jaký má zástava požadovaná od podniků vnímaných negativně. Výrazné zatížení majetku zástavním břemenem může tedy pramenit z nemožnosti uzavření věřitelsko-dlužnického vztahu bez zajištění zástavou, a tedy z negativních očekávání ze strany ostatních subjektů. Kladné znaménko, přiřazené této proměnné v rámci výsledné diskriminační funkce, je tedy v souladu s očekáváním plynoucím z obou interpretací ukazatele.

<sup>193</sup> Viz příloha III.

<sup>194</sup> Hranice podmnožin oboru hodnot viz výše.



Dalšími ukazateli, jejichž vyšší hodnoty sdělují v tradiční finanční analýze spíše negativní hodnocení podniku a i na základě právě provedené MDA posouvají podnik blíže ke skupině nebonitních firem, jsou proměnné  $X_{13LT}$  (doba splatnosti závazků) a  $X_{15L}$  (celková zadluženost). Ráda bych upozornila na soulad výsledku týkající se těchto dvou ukazatelů s očekáváním, plynoucím z hlavního účelu konkursního řízení. Zákon o konkursu a vyrovnání<sup>195</sup> deklaruje, že je jeho cílem uspořádat majetkové poměry dlužníka, který je v úpadku. Úpadek dlužníka je pak v zákoně především vymezen jako stav, kdy subjekt pozastavil platby svých závazků. S rostoucím objemem závazků po splatnosti nepochybně roste ukazatel  $X_{13LT}$ . U podniků, na něž byl v souvislosti s neplněním splatných závazků vyhlášen konkurs, je tedy možné očekávat, že bude podstatně vyšší než u prosperujících zdravých firem. Znaménko přiřazené tomuto ukazateli v rámci diskriminační funkce toto očekávání potvrzuje. Podnik je podle zákona o konkursu a vyrovnání kromě situace, kdy nehradí splatné závazky, za dlužníka v úpadku označen rovněž ve chvíli, kdy je předlužený. Otázka, zda se podniky, na které byl vyhlášen konkurs, skutečně od prosperujících podniků liší měrou své zadluženosti, je proto podle mého názoru rovněž na místě. Model na vyšší hodnoty celkové zadluženosti ( $X_{15L}$ ) firem skupiny 1 skutečně poukázal.

Očekávání ohledně ukazatele rentability vlastního jmění ( $X_{7LT}$ ) a indikátoru pohotovosti likvidity ( $X_{3LT}$ ) shrnutá v podkapitole věnované popisu jednotlivých ukazatelů byla rovněž naplněna. Znaménko u obou proměnných je záporné; jejich vyšší hodnoty posouvají firmu blíže ke skupině 2.

Vliv proměnné  $X_1$  (poměr pracovního kapitálu) je funkcí zachycen pomocí kladného znaménka, a jeho vyšší hodnoty tak posouvají posuzovaný podnik blíže ke skupině firem v konkursu. Podle teorie by však vyšší poměr pracovního kapitálu měl být standardně spíše předpokladem pro úspěšné splácení krátkodobých závazků. Očekáváno tedy bylo spíše záporné znaménko. Pracovní kapitál však roste s rostoucím objemem oběžných aktiv, která zahrnují vedle finančního majetku i méně likvidní formy aktiv. Jsou jimi zásoby a krátkodobé pohledávky. U podniků, tvořících velké objemy zásob, které negenerují dostatečný tok hotovosti, může být ukazatel poměru pracovního kapitálu vyšší než u podniků, reagujících pružně na poptávku a sledujících systém just-on-time. Negativní znaménko, které bylo ve funkci přiřazeno ukazateli pohotovosti likvidity ( $X_{3LT}$ ), naznačuje, že tento problém může být důvodem vyšších hodnot poměru pracovního kapitálu u podniků skupiny 1. Dalším teoreticky možným důvodem vyššího poměru pracovního kapitálu u problémových podniků je velký objem krátkodobých pohledávek po splatnosti, generující druhotnou platební neschopnost. K prozkoumání, zda je tento vliv přítomen i v pozorovaném případě, by bylo nutné zjistit závislost rozdělení podniků do skupin na některém z ukazatelů likvidity očištěném o pohledávky po splatnosti.<sup>196</sup> Tento údaj jsem však bohužel neměla k dispozici.

<sup>195</sup> Zákon č. 328/1991 Sb.

<sup>196</sup> Buchtíková (1999) zkoumá vliv ukazatele upravené běžné likvidity. Na vzorku firem členěném podle platební disciplíny vůči bankám byl uvedený předpoklad rozdílu v objemech pohledávek po splatnosti potvrzen. Zajímavé by bylo rovněž zkoumání tvorby opravných položek k nedobytným pohledávkám.

Jak nastínila již tabulka 3, nejvýznamnější měrou k diskriminaci přispěly proměnné spojené se zadlužeností podniku a s jeho schopností splácet závazky. Analýza tedy potvrdila očekávání rozdílů mezi podniky plynoucí ze zákonem vymezených vlastností podniků v úpadku. Zároveň poukázala na proměnné, které bývají v souvislosti s bonitou podniků běžně posuzovány. Z hlediska identifikace důležitých vlivů tedy nepřinesla žádný revoluční nástroj analýzy.

Vedle zmíněné možnosti použít diskriminační analýzu jako nástroj identifikace důležitých souvislostí však existuje, jak jsem zmínila, ještě další forma použití výsledků analýzy. Je jí predikce finančního zdraví na základě klasifikace nových pozorování s neznámou hodnotou závisle proměnné.

Možnost aplikace výsledné funkce v této oblasti je vhodné předem zhodnotit pomocí testů klasifikační schopnosti. V následujících odstavcích se proto postupně zaměřím na testy schopnosti klasifikace na primárních, respektive sekundárních datech:

Následující klasifikační matice shrnuje výsledky testu na primárních datech – datech použitých pro konstrukci funkce.<sup>197</sup>

Classification Matrix_primary data			
Rows: Observed classifications			
Columns: Predicted classifications			
	Percent	G_1:1	G_2:2
	Correct	p=,30435	p=,69565
G_1:1	85,7	18	3
G_2:2	100,0	0	48
Total	95,7	18	51

**tabulka 5** Klasifikační matice výsledné funkce Analýzy 1 – test na primárních datech

Pozn.: G\_1 značí skupinu 1 – podniky v konkursu; G\_2 reprezentuje skupinu 2 – prosperující podniky.

Jak je vidět, výsledná funkce klasifikuje data, na jejichž základě byla vytvořena, správně v 95,7 % případů. Je také zřejmé, že funkce lépe rozpoznává skupinu 2. Při jejím použití pro klasifikaci primárních dat zařadila správně všechny prosperující podniky a generovala tak nulovou chybu  $\beta$ . Chyba  $\alpha$  je o poznání vyšší, přibližně 14 %. Vyšší procento chybné klasifikace firem skupiny 1 je pravděpodobně způsobeno nestandardní podobou finančních výkazů firem skupiny 1. To může pramenit ze skutečnosti, že konkurs je vyhlášován na firmy, které se potýkají s různou podobou finančních těžkostí.<sup>198</sup> Dalším potenciálním zdrojem tohoto jevu může též být skutečnost, že jsou data ve finančních výkazech ve chvíli, kdy si je již management podniku vědom tíživé finanční situace, vystavena záměrné manipulaci. Cílem může být právě úprava hodnot klíčových ukazatelů tak, aby bylo i přes nepříznivé vyhlídky firmy možné získat zdroje financování.

<sup>197</sup> Jedná se o validaci funkce pomocí empirické metody. Viz podkapitola 3.2.1.1.1.

Na základě výsledků testu pomocí primárních dat, které zachycuje tabulka 5, lze očekávat, že případné výsledky použití zvolené funkce pro predikci finanční situace bude generovat vyšší procenta chyby  $\alpha$  než chyby  $\beta$  a že výsledné hodnoty předpovídající finanční zdraví budou méně spolehlivé než hodnoty předpovídající konkurs. Pokud by chyba typu  $\alpha$  představovala ve srovnání s chybou typu  $\beta$  relativně vyšší náklady, bylo by podle mého názoru u firem s výslednými hodnotami aposteriorních pravděpodobností generujících nejednoznačnost zařazení do skupiny prosperujících podniků nutné provést dodatečnou analýzu.<sup>199</sup>

Jak již bylo vícekrát zdůrazněno, bývají testy klasifikační schopnosti pomocí empirické metody příliš optimistické. Lze z nich vytvářet závěry pouze v souvislosti s dalšími testy. Pro posouzení hypotézy o tom, že obě skupiny pocházejí se stejné populace, použijí test křížovou metodou<sup>200</sup> v jednom opakování. Sekundární vzorek je tvořen daty, která nebyla použita pro provedení analýzy.

K předpovědím zařazení sekundárních dat do skupin jsem použila dvě klasifikační funkce, které program Statistica nabízí ve výstupu diskriminační analýzy do dvou skupin.<sup>201</sup> Parametry obou funkcí shrnuje tabulka 6.

Classification Functions; grouping: K_P		
	G_1:1	G_2:2
	p=,30435	p=,69565
X18LT	15,228344	4,981542587
X13LT	13,2223043	10,30085754
X15L	4,36602545	1,158187985
X7LT	-2,6637046	-1,53053582
X1	18,8002853	11,22144413
X3LT	1,05753016	2,834139585
Constant	-51,791157	-30,1629333

**tabulka 6** Klasifikační funkce plynoucí z Analýzy 1.

<sup>198</sup> Hodnoty ukazatelů podniku, který primárně pocítil výsledkovou krizi, mají odlišný vývoj než ukazatele za podnik, v jehož případě byla prvotním důvodem úpadku krize rozvahová. Od obou případů odlišný je i vývoj ukazatelů podniku, který vykázal druhotnou platební neschopnost.

<sup>199</sup> Úvahu o doplňující analýze v případě nejednoznačných hodnot aposteriorních pravděpodobností zahrnuje podkapitola 3.2.1.2.2.

<sup>200</sup> Viz podkapitola 3.2.1.1.2.

<sup>201</sup> Při testování klasifikační schopnosti bez využití programu je možné aplikovat diskriminační funkci spolu s předem zjištěnými intervaly hodnot pro obě skupiny. Využití klasifikačních funkcí vygenerovaných statistickým programem je metodologicky odlišné a zároveň jednodušší: Po dosazení hodnot nezávisle proměnných do obou z nich obdržíme pro každé pozorování dvě hodnoty. Podle toho, který z výsledků je větší, můžeme předpovědět zařazení pozorování do příslušné skupiny. Diskriminace pomocí doprovodných klasifikačních funkcí je jednoznačná, problém s šedou zónou zde nenastává.

Výsledky testu provedeného pomocí sekundárních dat jsou shrnuty v následující klasifikační matici:

Classification Matrix_secondary data			
Rows: Observed classifications			
Columns: Predicted classifications			
	Percent Correct	G_1 p=,54286	G_2 p=,45714
G_1	84,2	16	3
G_2	93,8	1	15
Total	88,6	17	18
Adjusted*	90,6	n/a	n/a

**tabulka 7** Klasifikační matice výsledné funkce analýzy 1 – test na sekundárních datech

Poznámky:

Adjusted\* – upravená celková chyba (vážený průměr chyb s použitím předpokládaného poměru skupin 3:7)

G\_1 – skupina 1 – podniky v konkursu

G\_2 – skupina 2 – prosperující podniky

Jak je zřejmé z počtů pozorování v jednotlivých skupinách, byl pro testy pomocí křížové metody použit soubor sekundárních dat, který měl jiný poměr zastoupení podniků skupin 1 a 2 než soubor primárních dat.<sup>202</sup> Výsledná chyba typu  $\alpha$  (15,8 %), která je stejně jako u testů na primárních datech podstatně vyšší než chyba  $\beta$  (6,2 %), tak do výpočtu celkové chyby klasifikace vstupuje s větší vahou a generuje celkovou chybu 11,4 %. Za účelem dosažení srovnatelnosti výsledků jednotlivých testů klasifikační schopnosti funkce jsem dále spočetla upravenou chybu klasifikace, a to tak, že jsem váhy jednotlivých typů chyb ve výpočtu celkové chyby přizpůsobila poměru apriorních pravděpodobností, použitému při analýze (3:7).<sup>203</sup> Takto vážená chyba klasifikace dosáhla hodnoty 9,4 %. Výsledky testu pomocí sekundárních dat jsou při zvoleném rozsahu vzorku přirozeně záležitostí náhodnou, mohou tedy sloužit spíše jako dílčí signál o klasifikační schopnosti funkce. Významnost velmi povzbuzujícího výsledku provedeného testu může být nejlépe ověřena dalším testováním na rozsáhlejších souborech či srovnáváním s výsledky klasifikace dosažené pomocí jiných modelů.

Jak jsem již zmínila, byla právě rozebraná analýza vytvořena na základě zúženého souboru dat.<sup>204</sup> Pro posouzení dopadů vyřazení proměnných, které nesplňovaly normální rozdělení, je podle mého názoru užitečné srovnání výsledků takto dosažených s výsledky aplikace MDA

<sup>202</sup> V sekundárním vzorku bylo 19 podniků skupiny 1 a 16 podniků skupiny 2. Test je tedy zaměřen zejména na schopnost klasifikace nebonitních podniků, která byla na základě předchozího testu označena za horší.

<sup>203</sup> Jinou možností by byl sběr dalších dat o prosperujících podnicích tak, aby sekundární vzorek vykazoval stejný poměr apriorních pravděpodobností jako vzorek primární.

<sup>204</sup> Viz podkapitola 5.2.4.

na původní soubor 18 proměnných. Ze shrnutí výstupu Analýzy 1a, uvedeného v příloze III, a z jeho porovnání s právě prezentovanými výsledky je vidět, že provedené úpravy souboru dat vedly k dosažení modelu, který vysvětluje větší podíl diskriminace do skupin.

K dalšímu porovnání obou modelů nepochybně přispěje vzájemné srovnání výsledků testů klasifikačních schopností i jejich komparace s výsledky referenčních modelů. Obojí je zahrnuto v podkapitole 5.4.

Analýza závislosti konkursu na ukazatelích těsně před obdobím pozorování výsledného stavu ukázala v obou případech zejména na silnou vypovídací schopnost ukazatelů zadlužení společnosti a její schopnosti splácet závazky. Tuto závislost lze vzhledem k právně uznatelným důvodům vyhlášení konkursu očekávat. Z hlediska této práce je však důležité pokusit se zodpovědět otázku, zda můžeme získat upozornění na eventualitu, že potenciální obchodní partner spěje ke konkursu, ještě dříve, než to začne signalizovat předlužení či prodlevy ve splácení. Z toho důvodu jsem podnikla další analýzy. První z nich modeluje závislost konkursu na proměnných spočtených z finančních výkazů dva roky před vyhlášením konkursu. Její výsledky prezentuji v následující podkapitole. Druhá je poněkud komplexnější – je zaměřena na výběr nejvýznamnějších proměnných poukazujících na možnost konkursu po dobu obou období. Její výsledky jsou uvedeny v oddíle 5.3.3.

### 5.3.2. Analýza 2: dva roky před konkursem

Aby bylo možné předvídat hrozící konkurs dříve, než na něj začne poukazovat předlužení, je třeba vytipovat významné závislosti finanční tísně na zpožděných proměnných. Proto jsem se rozhodla provést diskriminační analýzu vztahu konkursu na datech za období 2 roky před jeho vyhlášením. Výsledky této analýzy rovněž pomohou testovat hypotézu o shodnosti koeficientů proměnných zpožděných o jedno a více období.

Výsledná funkce, jejíž výběr byl založen na dopředné krokové MDA,<sup>205</sup> má tvar:

$$D = 3,6247 - 3,8997.X_{18\_2LT} - 0,4020.X_{13\_2LT} + 0,1994.X_{4\_2L}.$$

Pro podniky skupiny 1 nabývá hodnot  $D < -1,6950$ , pro podniky skupiny 2 pak hodnot  $D > 0,74154$ . Hodnoty intervalu  $<-1,6950; 0,74154>$  negenerují přiřazení k žádné ze skupin. Příspěvek jednotlivých proměnných zahrnutých do funkce je zachycen v následující tabulce.

---

<sup>205</sup> Jedná se o postup opačný, než jaký v sobě zahrnuje analýza zpětná, použitá v předchozí pasáži. Při dopředné krokové analýze jsou postupně jednotlivé proměnné zahrnovány do modelu na základě porovnání jejich dodatečného příspěvku k diskriminaci a předem stanovené úrovni „F-to-enter“.

Discriminant Function Analysis Summary (new.sta)						
Step 3, N of vars in model: 3; Grouping: K_P (2 grps)						
Wilks' Lambda: ,43584 approx. F (3,65)=28,045 p< ,0000						
	Wilks'	Partial	F-remove			1-Toler.
	Lambda	Lambda	(1,65)	p-level	Toler.	(R-Sqr.)
X18_2LT*	0,80857	0,539028	55,5874	0,00000000	0,990899	0,00910109
X13_2LT*	0,46521	0,936883	4,37896	0,04029379	0,985755	0,01424474
X4_2L	0,45727	0,953137	3,19586	0,07848652	0,977091	0,02290851

**tabulka 8** Shrnutí proměnných zahrnutých do modelu při Analýze 2

Pozn.: Závislost diskriminace na proměnných označených hvězdičkou je významná na pětiprocentní hladině.

K vysvětlení konkursu pomocí dat za období 2 roky před vyhlášením tedy nejvíce přispívají následující ukazatele:

- zatíženost HIM ( $X_{18\_2LT}$ );
- doba splatnosti závazků ( $X_{13\_2LT}$ );
- okamžitá likvidita ( $X_{4\_2}$ ).

I při zkoumání ukazatelů za období 2 roky před pozorovaným stavem firmy diskriminační analýza poukázala na závislost finanční situace zejména na ukazatelích, popisujících zadluženost firmy ( $X_{13\_2LT}$  a  $X_{18\_2LT}$ ). Výsledná funkce v souladu s očekáváním přiřazuje těmto ukazatelům záporné znaménko a posouvá je blíže k oboru hodnot D pro podniky v konkursu. Další z proměnných, přispívajících k vysvětlení finanční situace firmy v rámci výsledné funkce, je ukazatel okamžité likvidity.<sup>206</sup> Jeho vyšší hodnoty v souladu s očekáváním signalizují příslušnost podniku k prosperujícím firmám.

Tyto poznatky, týkající se určení proměnných, které je třeba zkoumat v rámci jiných analýz, rozšířily závěry ze zkoumání rozdělení podniků do skupin pomocí ukazatelů bezprostředně před vyhlášením konkursu bohužel pouze v omezené míře. Než přistoupím k analýze ukazatelů za obě dvě období před konkursem současně, která bude zaměřena na zachycení důležitých vlivů s ohledem na časovou návaznost činnosti firmy, zastavím se ještě krátce u testování klasifikační schopnosti funkce vysvětlující konkurs pouze pomocí zpožděných proměnných.

<sup>206</sup> Její vliv však nebyl významný na pětiprocentní hladině.

První z testů klasifikační síly zvolené funkce - test empirickou metodou - je shrnut v následující tabulce:

Classification Matrix_primary data			
Rows: Observed classifications			
Columns: Predicted classifications			
	Percent Correct	G_1 p=,30435	G_2 p=,69565
G_1	85,7	18	3
G_2	93,8	3	45
Total	91,3	21	48

**tabulka 9** Klasifikační matice výsledné funkce analýzy 2 – test na primárních datech

Je zřejmé, že z podniků, na základě jejichž údajů byla vytvořena, klasifikuje funkce lépe prosperující podniky. Stejně tomu tak bylo i u funkce vybrané na základě analýzy dat bezprostředně před vyhlášením konkursu. Funkce správně zařadila 45 ze 48 prosperujících podniků. Její aplikace na primární data tedy generovala chybu  $\beta$  o velikosti 7,2 %. Jak bude vidět ze srovnání výsledků klasifikačních testů s výsledky referenčních modelů na konci této kapitoly, jedná se o poměrně povzbuzující informaci. Přesto však upozorňuje na méně jasnou hranici mezi podniky, které budou za dva roky prosperovat, a podniky, na které bude ve stejné době vyhlášen konkurs.

Chyba typu  $\alpha$  na primárních datech je u funkce vysvětlující konkurs pomocí dat zpožděných o dvě období stejná, jako chyba  $\alpha$  generovaná funkcí zachycující závislost konkursu na datech rok před jeho vyhlášením, tedy 14,3 %.

Validace funkce pomocí sekundárních dat, zaměřená na detekci případných vychýlení vstupních dat, byla provedena s použitím klasifikačních funkcí s koeficienty, které zachycuje následující tabulka:

Classification Functions; grouping: K_P		
	G_1	G_2
	p=,30435	p=,69565
X18_2LT	11,5346575	2,032953501
X13_2LT	8,2833786	7,303844452
X4_2L	-0,9353523	-0,44937867
Constant	-30,702774	-19,8829308

**tabulka 10** Klasifikační funkce plynoucí z Analýzy 2

Aplikace těchto klasifikačních funkcí na sekundární data přinesla následující výsledky:

Classification Matrix_ secondary data			
Rows: Observed classifications			
Columns: Predicted classifications			
	Percent Correct	G_1 p=,54286	G_2 p=,45714
G_1	47,4	9	10
G_2	87,5	2	14
Total	65,7	11	24
Adjusted*	74,1	n/a	n/a

**tabulka 11** Klasifikační matice výsledné funkce analýzy 2 – test na sekundárních datech

Pozn.: Adjusted\* – upravená celková chyba (vážený průměr chyb s použitím předpokladu poměru skupin 3:7),

G\_1 – skupina 1 – podniky v konkursu,

G\_2 – skupina 2 – prosperující podniky.

Celková chyba klasifikace dosáhla v tomto případě 34,3 %, tedy výsledku o mnoho horšího než u primárních dat. Nejvíce k tomu přispěl podíl chybně zařazených podniků v konkursu, generující chybu  $\alpha$  o velikosti 52,6 %. Upravená celková chyba, jejíž hodnotu jsem obdržela vážením chyb  $\alpha$  a  $\beta$  pomocí apriorních pravděpodobností předpokládaných při konstrukci modelu, má velikost 25,9 %. I když přinesla uvedená úprava o něco optimističtější výsledek, funkce zdaleka nedosáhla tak dobré rozpoznávací schopnosti sekundárních dat jako funkce popsaná v předchozí podkapitole. Výsledek testu klasifikační schopnosti křížovou metodou tedy potvrdil podezření, že se hranice mezi oběma skupinami podniků při pohledu dále do minulosti stírá. Je z něho patrné, že odlišnost skupin podniků se v čase mění a že koeficienty proměnných za jednotlivá po sobě jdoucí období nejsou identické.

Výsledky popsané analýzy jsou i přes uvedenou sníženou rozlišovací schopnost o poznání lepší než výsledky testů klasifikační schopnosti modelu, vytvořeného za uvažování všech původně zvolených proměnných bez transformace.<sup>207</sup> Jak je vidět především z výsledné hodnoty Wilksovy lambdy, výsledku testu  $\chi$ -kvadrát, z hodnot druhých mocnin Mahanobilisovy vzdálenosti mezi jednotlivými skupinami a z dalších charakteristik modelu, uvedených v příloze III, funkce vybraná při nesplnění předpokladů aplikace MDA u některých vstupních proměnných (Analýza 2a) je schopna vysvětlit rozčlenění do skupin o poznání méně než model prezentovaný v předchozích odstavcích. Dopady nesplnění předpokladů je možné pozorovat také z výsledků testu klasifikační schopnosti empirickou i křížovou metodou, které uvádím v podkapitole 5.4. Je tedy vidět, že kombinace ukazatelů, zvolená na základě Analýzy 2b, mnohem lépe vysvětluje rozdělení do skupin než kombinace vybraná v rámci Analýzy 2a.

<sup>207</sup> Parametry modelu a výsledky testů statistické významnosti a klasifikační schopnosti jsou uvedeny v příloze III.



Stírání rozdílu mezi skupinami firem při pohledu na výkazy staršího data je patrné již nyní. Ukazatele za dvě období před konkursem nemohou vysvětlit nadcházející konkurs tak dobře, jako ukazatele o jedno období novější. Abych ohodnotila diskriminační sílu zpožděných proměnných při společném působení s proměnnými novějšími, provedu další analýzu, do které jako vstupy zařadím ukazatele za obě periody předcházející období, ve kterém byl pozorován stav firmy.

### 5.3.3. Analýza 3: obě období před konkursem

Analýza rozdělení podniků do skupin pomocí proměnných za dvě období před pozorováním stavu firmy (Analýza 2) generovala funkci s parametry naprosto odlišnými od parametrů ve výsledné rovnici Analýzy 1. Za její pomoci bylo navíc možné odlišit skupiny podniků v sekundárním vzorku ve velmi omezené míře. To upozornilo na nedostatečnost samostatné vypovídací schopnosti o dvě období zpožděných proměnných.

Pro ucelení obrazu o možnostech využití MDA pro predikci finanční tísně českých podniků pokládám za přínosné zkoumat příspěvek zpožděných proměnných k diskriminaci v souvislosti se společnou diskriminační silou proměnných za obě období. Analýza obou období současně pomůže zachytit mezičiasovou interakci proměnných.

Protože jsem pro tuto analýzu měla k dispozici rozšířený soubor proměnných, vznikl větší prostor pro úpravy jejich struktury.<sup>208</sup> Po zúžení tohoto souboru na základě úprav dat popsaných v podkapitole 5.2.4.2.3 jsem měla k dispozici soubor 18 proměnných.<sup>209</sup>

Příspěvek jednotlivých proměnných zahrnutých do zvolené kombinace na základě dopředné krokové diskriminační analýzy zachycuje tabulka 12.

Discriminant Function Analysis Summary (new.sta)						
Step 3, N of vars in model: 3; Grouping: K_P (2 grps)						
Wilks' Lambda: ,29022 approx. F (3,65)=52,988 p< ,0000						
	Wilks'	Partial	F-remove			1-Toler.
Variable	Lambda	Lambda	(1,65)	p-level	Toler.	(R-Sqr.)
X18LT*	0,68889	0,421294	89,2865	0,00000000	0,905732	0,09426761
X13LT*	0,34097	0,851171	11,3654	0,00126351	0,893184	0,10681623
X17L*	0,32041	0,905794	6,76028	0,01152526	0,866506	0,13349426

**tabulka 12** Shrnutí proměnných zahrnutých do modelu při analýze 3

Pozn.: Závislost diskriminace na proměnných označených hvězdičkou je významná na pětiprocentní hladině.

<sup>208</sup> V souvislosti s jejich vzájemnou korelovaností.

<sup>209</sup> Jedná se o celkový počet proměnných za obě období: Pracovala jsem s proměnnými  $X_1, X_2, X_{4L}, X_6, X_{7LT}, X_{11L}, X_{13LT}, X_{14}, X_{17L}, X_{18LT}$  za jedno období před konkursem a s proměnnými  $X_{1,2}, X_{2,2}, X_{4,2L}, X_{11,2LT}, X_{13,2LT}, X_{14,2}, X_{17,2L}, X_{18,2LT}$ . Index L značí proměnné, získané transformací pomocí funkce přirozeného logaritmu. Index LT označuje proměnné, získané transformací pomocí složené funkce, popsané v poznámce 181.

Jak vyplývá z předchozí tabulky, analýza ukázala na závislost stavu firmy na následujících proměnných:

- zatíženost HIM ( $X_{18LT}$ );
- doba splatnosti závazků ( $X_{13LT}$ );
- míra zadluženosti ( $X_{17L}$ ).<sup>210</sup>

Výsledná diskriminační funkce má tvar:

$$Z = 3,782256 - 2,4532 X_{18LT} - 0,56039 X_{13LT} - 0,54795 X_{17L}$$

Hodnoty  $Z > 1,01928$  generují příslušnost ke skupině 2, hodnoty  $Z < -2,32979$  poukazují na podobnost s podniky ve skupině 1. Hodnota funkce v intervalu  $\langle -2,32979; 1,01928 \rangle$  neumožňuje jednoznačné přiřazení podniku do jedné ze skupin.

K posouzení samostatné diskriminační síly každé z proměnných zahrnutých do modelu uvádím ještě velikosti jednotlivých standardizovaných koeficientů:

Standardized Coefficients for Canonical Variables	
	Root 1
X18LT*	-0,948786438
X13LT*	-0,484521836
X17L*	-0,39137575
Eigenval	2,445610046
Cum.Prop	1

**tabulka 13** Standardizované koeficienty funkce zvolené na základě Analýzy 3

Pozn.: Závislost diskriminace na proměnných označených hvězdičkou je významná na pětiprocentní hladině.

Je zřejmé, že vysoké hodnoty proměnné zatížení hmotného investičního majetku ( $X_{18LT}$ ), která na základě provedené analýzy přispívá k vysvětlení rozdělení do skupin nejvíce, posouvají pozorování blíže ke skupině 1. S ohledem na skutečnost, že tato proměnná zachycuje podíl majetku zatíženého zástavním právem či jinými břemeny, a že se tedy jedná o ukazatel související se zadlužením podniku, je tento výsledek v souladu s očekáváním. Vysoká diskriminační síla tohoto ukazatele dále nastiňuje, že podání návrhu na vyhlášení konkursu pravděpodobně souvisí s očekáváním věřitelů daného podniku.<sup>211</sup>

<sup>210</sup> Index L...proměnná získaná transformací pomocí funkce přirozeného logaritmu, index LT...proměnná transformovaná složenou funkcí popsanou v poznámce 181.

<sup>211</sup> Významný vliv tohoto ukazatele byl napozorován a diskutován v případě Analýzy 1 (viz podkapitola 5.3.1)

Směr vlivu další z proměnných – doby splatnosti závazků ( $X_{13LT}$ ) posouvající podniky s dlouhou dobou splácení krátkodobých závazků dále ke skupině 1 – je též v souladu s očekáváním. V souvislosti s vyhlášením konkursu je samozřejmě důležitější zkoumání objemu závazků po splatnosti. Informaci o jejich stavu však nebylo v rámci této práce možné získat. Doba splatnosti závazků je však nepochybně rostoucí funkcí objemu závazků po splatnosti. Proto se domnívám, že výsledek týkající se proměnné  $X_{13LT}$  může zároveň signalizovat závislost vyhlášení konkursu na skutečně snížené platební disciplíně.

Vliv proměnné  $X_{17L}$ , která zachycuje míru zadlužení společnosti, je rovněž v souladu s očekáváním utvořeným na základě cíle konkursního řízení podle zákona.

Kombinace proměnných, jejíž schopnost vysvětlit rozdíly mezi pozorovanými skupinami podniků byla v rámci poslední analýzy vyhodnocena jako nejlepší, zahrnovala pouze ukazatele za období těsně před konkursem. Tři proměnné, zachycující zadluženost podniku, respektive dobu splácení běžných závazků, jsou schopny diskriminaci vysvětlit z 84 %.<sup>212</sup> K této míře vysvětlení nepřispěly žádné proměnné zpožděné o dvě období ani žádný z ukazatelů likvidity či rentability.<sup>213</sup>

Abych posoudila, do jaké míry je vhodné uvedenou funkci aplikovat na predikci finanční tísně, provedla jsem testy její klasifikační schopnosti. Stejně jako u předchozích analýz jsem nejdříve provedla test funkce pomocí empirické metody. Jeho výsledky jsou shrnuty následující klasifikační maticí:

Classification Matrix			
Rows: Observed classifications			
Columns: Predicted classifications			
	Percent	G_1:1	G_2:2
	Correct	p=,30435	p=,69565
G_1:1	90,48	19	2
G_2:2	100,00	0	48
Total	97,10	19	50

**tabulka 14** Klasifikační matice výsledné funkce Analýzy 3 – test na primárních datech

Použitím vybrané funkce pro predikci stavu firem zařazených do analýzy bychom se dopustili 2,9 % chyby klasifikace. Opět funkce lépe rozpoznává podniky skupiny 2: Prosperující podniky použité pro konstrukci modelu byly za jeho pomoci klasifikovány perfektně – chyba typu  $\beta$  je tedy nulová. Špatně rozpoznala funkce jen 2 podniky ze skupiny 1, a dopustila se tak na primárních datech chyby typu  $\alpha$  ve výši 9,52 %.

<sup>212</sup> Viz příloha III.

<sup>213</sup> Vliv rentability by podle mého názoru bylo možné lépe prozkoumat v případě analýzy dat za podniky operující ve stejném odvětví.

Test výsledků analýzy pomocí sekundárních dat byl proveden s použitím následujících klasifikačních funkcí:

Classification Functions; grouping:		
K_P	G_1:1	G_2:2
Variable	p=,30435	p=,69565
X18LT	10,7814016	2,565455437
X13LT	10,2478571	8,37105751
X17L	-2,4283733	-4,26350689
Constant	-40,138809	-24,4505596

**tabulka 15** Parametry klasifikačních funkcí plynoucích z Analýzy 3

Aplikace klasifikačních funkcí na sekundární data a následné porovnání výsledných hodnot pro obě funkce generovalo klasifikaci podniků, jejíž úspěšnost je zřejmá z následující matice:

Classification Matrix_secondary data			
Rows: Observed classifications			
Columns: Predicted classifications			
	Percent Correct	G_1 p=,54286	G_2 p=,45714
G_1	94,7	18	1
G_2	93,8	1	15
Total	94,3	19	16
Adjusted*	94,1	n/a	n/a

**tabulka 16** Klasifikační matice výsledné funkce analýzy 3 – test na sekundárních datech

Pozn.: Adjusted\* – upravená celková chyba (vážený průměr chyb s použitím předpokladu poměru skupin 3:7),

G\_1 – skupina 1 – podniky v konkursu,

G\_2 – skupina 2 – prosperující podniky.

Výsledná chyba typu  $\beta$  je 6,2 %. Chyba typu  $\alpha$  je oproti většině předchozích testů při tomto testu o něco nižší, a to 5,3 %. Celková chyba klasifikace dosahuje hodnoty 5,7 %. Vážení obou typů chyb vahami, danými předpokládaným poměrem obou skupin v populaci, přineslo hodnotu upravené celkové chyby klasifikace ve výši 5,9 %. Výsledky testu klasifikační schopnosti funkce křížovou metodou jsou podle mého názoru velmi povzbudivé a podnětné pro další využití při predikci finanční situace. Jak je zřejmé, ani analýza vztahů ukazatelů v obou obdobích zároveň nepoukázala na to, že by diskriminační síla ukazatelů za období dvou let před pozorováním stavu firem byla dostatečně silná, aby za jejich pomoci bylo možné předpovídat nebezpečí konkursu s dostatečným předstihem.

Jak jsem zmínila, byly z množiny vstupů v případě poslední analýzy vyřazeny oproti analýzám předchozím kromě proměnných nesplňujících předpoklad normality i proměnné silně korelované

s jinými proměnnými. Odpověď na otázku, zda toto opatření pomohlo vylepšit klasifikační schopnost funkce, nám pomůže nalézt srovnání testů klasifikační schopnosti jednotlivých modelů, uvedené v následující kapitole.

#### 5.4. Srovnání výsledků vlastních analýz s referenčními modely

V následující pasáži se zaměřím na srovnání výsledků jednotlivých analýz, provedených v rámci této práce, s cílem posoudit, jaký vliv měly úpravy vstupních souborů dat na klasifikační schopnost výsledných funkcí. Zároveň podrobím výsledky vlastních analýz srovnání se závěry, ke kterým dospěli autoři studií využití MDA, diskutovaných v předchozí kapitole.<sup>214</sup>

##### 5.4.1. Srovnání výsledků testů klasifikační schopnosti empirickou metodou

Nejprve se zaměřím na srovnání testů klasifikační schopnosti pomocí empirické metody, tedy aplikací funkce na primární data. Následující tabulka shrnuje hodnoty správné klasifikace, respektive chyb, které uvedli sami autoři, s hodnotami, které jsem spočetla a uvedla v rámci v podkapitol, prezentujících výsledky jednotlivých analýz.<sup>215</sup>

Studie	Altman (1968)	Buchtíková (1998)	Analýza 1a	Analýza 1b	Analýza 2a	Analýza 2b	Analýza 3
Počet pozorování ve skupině 1	33	103	21	21	21	21	21
Počet pozorování ve skupině 2	33	391	48	48	48	48	48
Počet správných klasifikací firem typu 1	31	78	16	18	9	18	19
Počet správných klasifikací firem typu 2	32	336	47	48	47	45	48
Správná klasifikace firem typu 1 (%)	94	75,7	76	85,7	42,9	85,7	90,5
Správná klasifikace firem typu 2 (%)	97	85,9	98	100	97,9	93,8	100
Správná klasifikace celkem (%)	95	83,8	91	95,7	81,2	91,3	97,1
Chyba typu $\alpha$ (%)	6	24,3	24	14,3	57,1	14,3	9,5
Chyba typu $\beta$ (%)	3	14,1	2	0	2,1	6,2	0
Celková chyba (%)	5	16,2	9	4,3	18,8	8,7	6,9

**tabulka 17** Přehled výsledků testů klasifikační schopnosti funkcí na primárních datech

Pozn.: skupina 1 – u Altmana firmy, které zbankrotovaly; u Buchtíkové ztrátové úvěry; u Analýz 1a – 3 firmy v konkursu; skupina 2 – u Altmana a Analýz 1a-3 prosperující firmy; u Buchtíkové standardní úvěry.

Nejnižší schopnost klasifikovat správně primární data vykázala funkce vybraná na základě analýzy netransformovaného souboru dat za dvě období před konkursem (Analýza 2a). V podkapitole 5.3.2 jsem již upozornila na poměrně pesimistické hodnoty jednotlivých statistik poukazujících

<sup>214</sup> Altman (1968), Buchtíková (1998).

<sup>215</sup> Viz podkapitoly 5.3.1, 5.3.2 a 5.3.3.

na málo významné vysvětlení diskriminace pomocí proměnných použitých v rámci této analýzy.<sup>216</sup> Nyní je patrná i míra, v jaké se struktura dat projevila v nízkém počtu správných klasifikací. Vysokou míru chyby vykázala funkce zejména u podniků v konkursu. Při předpokladu vyšších nákladů chyby  $\beta$  by mohlo být použití podobného systému pro posuzování bonity klientů pro banku velmi nákladné.

Všechny posuzované funkce mezi podniky, na jejichž základě byly zkonstruovány, lépe rozeznávaly firmy typu 2 – chyba typu  $\beta$  je u všech analýz menší než chyba  $\alpha$ . Nejmenší chybu typu  $\beta$  můžeme pozorovat u Altmanovy funkce. Její výsledky jsou také velmi vyrovnané – dokáže diskriminovat se srovnatelnou chybou  $\alpha$ .

Nejmenší celkové chyby se však na primárních datech dopouští funkce vybraná v rámci Analýzy 1b, tedy při rozboru vlivů proměnných jedno období před pozorováním stavu firmy při použití transformovaných proměnných. Její schopnost klasifikovat primární data je ještě o 0,7% lepší než výkonnost Altmanovy funkce.

#### 5.4.2. Srovnání výsledků testů klasifikační schopnosti křížovou metodou

Pro získání přehledu o dopadech použití různých struktur dat však uvedené porovnání výsledků klasifikace primárních dat nepostačí. Uvádím proto další srovnání, týkající se výsledků testů klasifikace sekundárních dat. Protože v rámci publikované části studie Aleny Buchtíkové nebyl výsledek takového testu k dispozici, uvádím pouze srovnání testování výsledků Analýz 1a – 3 s testy výsledné Altmanovy funkce.<sup>217</sup>

Studie	Altman	Analýza 1a	Analýza 1b	Analýza 2a	Analýza 2b	Analýza 3
Počet pozorování ve skupině 1	25	19	19	19	19	19
Počet pozorování ve skupině 2	66	16	16	16	16	16
Počet správných klasifikací firem typu 1	24	17	16	7	9	18
Počet správných klasifikací firem typu 2	52	16	15	3	14	15
Správná klasifikace firem typu 1 (%)	96	90,5	84,2	36,8	47,4	94,7
Správná klasifikace firem typu 2 (%)	79	100	93,8	18,8	87,5	93,8
Správná klasifikace celkem (%)	83,5	96,5	90,6	24,8	74,1	94,1
Chyba typu alfa (%)	4	9,5	15,8	63,2	52,6	5,3
Chyba typu beta (%)	21	0	6,2	81,2	12,5	6,3
Celková chyba (%)	16,5	3,5*	9,4*	75,2*	25,9*	5,9*

**tabulka 18** Přehled výsledků testů klasifikační schopnosti funkcí na sekundárních datech

Pozn.: skupina 1 - u Altmana firmy, které zbankrotovaly; u Analýz 1-3 firmy v konkursu; skupina 2 - prosperující firmy; \*Celková chyba u analýz provedených v rámci této práce - vážený průměr obou typů chyb tak, aby byl splněn předpoklad poměru obou skupin v populaci (3:7).

<sup>216</sup> Charakteristiky modelu je možné komplexně pozorovat v příloze III.

<sup>217</sup> V další publikaci Aleny Buchtíkové (1999) jsou uvedeny výsledky aplikace modelu na historická data. Srovnání z důvodů uvedených v závěru čtvrté kapitoly nepovažuji za relevantní.

Z přehledu je patrné, že testy klasifikační schopnosti na základě sekundárních dat podaly nejlepší celkový výsledek v případě funkce, zvolené na základě Analýzy 1a. Ta vykázala celkové procento chybné klasifikace ve výši 3,5 %. Výsledky testů statistické významnosti kombinace proměnných, zvolených v rámci Analýzy 1a, uvedené v příloze III, však ukazují na nízkou významnost zvoleného modelu. Navíc, jak jsem uvedla, byla Analýza 1a provedena s použitím dat, která nesplňovala některé ze základních předpokladů aplikace MDA.<sup>218</sup> Výsledky dosažené na základě této analýzy nelze posuzovat bez ohledu na tuto skutečnost, neboť v jejím důsledku mohou být vychýlené kterýmukoli směrem.

S ohledem na tuto okolnost považuji za vhodné porovnat především modely vytvořené na základě Analýz 1b, 2b a 3.<sup>219</sup> Z porovnání těchto tří modelů vychází s hodnotou celkové chyby ve výši 5,9 % nejlépe funkce vytvořená na základě Analýzy 3. Tato funkce vykazuje navíc ve srovnání se všemi ostatními modely vytvořenými v rámci této práce nejnížší chybu typu  $\alpha$ : 5,3%. Vzhledem k tomu, že chyba typu  $\alpha$  představuje pro banku obvykle vyšší náklady než chyba typu  $\beta$ , generovala by tato funkce při posuzování úvěrových žádostí firem ze sekundárního vzorku rovněž nejnížší náklady. Protože je nákladové hledisko při rozhodování o volbě systému nepochybně velmi důležité, získává funkce vytvořená na základě Analýzy 3 dále na atraktivnosti oproti ostatním funkcím, které jsem vybrala v rámci této práce. Funkce generovaná Analýzou 3 klasifikovala navíc sekundární data téměř o jedno procento lépe než data primární.<sup>220</sup> Toto zlepšení by mohlo být v testech provedených na jiném vzorku sekundárních dat pochopitelně setřeno. I tak považuji výsledky týkající se Analýzy 3 za povzbudivé.

Na rozdíl od funkcí modelujících závislost konkursu pomocí starších dat jsou všechny funkce, které modelují závislost pomocí dat za období těsně před vyhlášením (funkce zvolené při Analýzách 1b a 3), při aplikaci na sekundární data z české ekonomiky poměrně úspěšné. Generují dokonce lepší výsledky, než jaké dala diskriminační funkce, již Altman v šedesátých letech modeloval závislost bankrotu amerických společností.

Popsaný výsledek je z hlediska posouzení klasifikační schopnosti modelů vytvořených v rámci této práce nepochybně pozitivní. Jsem však toho názoru, že je vhodné doplnit ho porovnáním výsledků aplikace Altmanovy metody a funkce vytvořené Buchtíkovou na stejný sekundární vzorek, jaký byl používán v rámci této práce. Výsledek tohoto testu přispěje také k nalezení odpovědi na otázku, kterou jsem nastínila podkapitole 4.3: Týká se přenositelnosti modelu v čase a prostoru.

---

<sup>218</sup> normalita rozdělení proměnných, homogenita kovariančních matic.

<sup>219</sup> Jedná se o modely, vytvořené s použitím dat transformovaných tak, aby lépe splňovaly předpoklady aplikace MDA.

<sup>220</sup> Podobné zlepšení můžeme pozorovat i v případě Altmanovy funkce u klasifikace zbankrotovaných firem (z 94 % na 96 % správné klasifikace).

### 5.4.3. Porovnání vhodnosti modelů pro vysvětlení finančních potíží českých podniků

Jak jsem uvedla v podkapitole 4.3., je vytvoření univerzální diskriminační funkce vhodné k předpovídání finanční situace firem kdekoli v prostoru a čase v praxi do jisté míry omezeno. Mezi nejvýznamnější omezení přenositelnosti funkce patří především odlišnost struktury zveřejňovaných finančních výkazů a z ní plynoucí rozdíly v dostupnosti ukazatelů vstupujících do diskriminačních funkcí. Další limity pak představují odlišnosti ve významu jednotlivých ukazatelů v různých ekonomikách a průběžné změny finanční situace jednotlivých firem v čase.

Nejdiskutovanější potenciální překážkou použití Altmanova skóre<sup>221</sup> pro klasifikaci českých podniků je ukazatel, označený v Altmanově původní funkci  $X_4$ . Jedná se o podíl tržní hodnoty vlastního jmění společnosti a účetní hodnoty jejího dluhu. Jak jsem již uvedla, pojí se diskuse na toto téma s úvahami o nízké likviditě kapitálového trhu, která vede k velmi omezenému obsahu uvedeného ukazatele. Skutečnost, že funkce není především pro použití uvedeného ukazatele vhodná pro neobchodované společnosti, zmenšuje rozsah možného využití původního Altmanova skóre ve finanční analýze.<sup>222</sup> Důvody tohoto typu vedly Altmana k úpravě ukazatelů a vah v původní funkci tak, aby zachycovala závislost finančního zdraví na ukazatelích neobchodovaných společností.<sup>223</sup> Původně použitý ukazatel tržní kapitalizace/účetní hodnota dluhu je v této funkci explicitně nahrazen podílem účetní hodnota vlastního jmění/účetní hodnota dluhu. Další odlišností jsou váhy přiřazené ukazatelům a hraniční hodnoty výsledného skóre.<sup>224</sup>

Ani tato úprava však nemůže bez dalšího testování vyvrátit hypotézu o omezené přenositelnosti funkce zkonstruované na datech za podniky pohybující se v různém čase a prostoru. Jsem toho názoru, že ji lze testovat pomocí posuzování výsledků, které jednotlivé funkce vykazují při aplikaci na data popisující jiné prostředí, než bylo to, v jehož rámci byla funkce vytvořena. Srovnání těchto výsledků s výsledky klasifikace podniků pomocí funkce vytvořené na datech za firmy z téže ekonomiky pak může dát určitý obrázek o přenositelnosti.

Následující tabulka zachycuje výsledky, jakých jsem dosáhla při aplikaci obou výše zmíněných Altmanových funkcí, vytvořených v šedesátých, respektive sedmdesátých letech na základě dat z americké ekonomiky, na data za české podniky v letech devadesátých. Pro porovnání je ve třetím sloupci uvedena klasifikace tohoto vzorku pomocí funkce vytvořené

---

<sup>221</sup> Konstrukce a tvar funkce - viz podkapitola 4.2.

<sup>222</sup> Z tohoto důvodu bývá pro lepší srovnatelnost mezi podniky místo tržní kapitalizace používán údaj o účetní hodnotě vlastního jmění.

<sup>223</sup> Funkce má tvar:  $Z = 0,998X_1 + 0,847X_2 + 3,107X_3 + 0,42X_4 + 0,998X_5$ .

Hodnoty  $Z$  menší než 1,2 poukazují na příslušnost ke skupině firem spějících k bankrotu, hodnoty vyšší než 2,9 naopak poukazují na schopnost firmy prosperovat.

<sup>224</sup> Viz pozn. 223 výše.



v rámci této práce.<sup>225</sup> Dále tabulka shrnuje údaje o klasifikaci, která byla výsledkem aplikace funkce vybrané Alenou Buchtíkovou<sup>226</sup> na tato data.

	A1	A2	B	Analýza 3
Počet pozorování ve skupině 1	19	19	19	19
Počet pozorování ve skupině 2	16	16	16	16
Počet správných klasifikací firem skupiny 1	15	14	0	18
Počet správných klasifikací firem skupiny 2	8	8	16	15
Počet chybných klasifikací firem skupiny 1	2	2	17	1
Počet chybných klasifikací firem skupiny 2	3	2	0	1
Počet výskytů nejednoznačného výsledku u firem typu 1	2	3	2	0
Počet výskytů nejednoznačného výsledku u firem typu 2	5	6	0	0
Procento správné klasifikace firem skupiny 1	78,9	73,7	0,0	94,7
Procento správné klasifikace firem skupiny 2	50,0	50,0	100,0	93,8
Celkové procento správné klasifikace	59,6	57,9	66,7	94,1

**tabulka 19** Porovnání výsledků funkcí při aplikaci na data za českou ekonomiku

Pozn.: A1 - původní Altmanova funkce pro obchodované společnosti; A2 - Altmanova funkce po úpravách pro neobchodované společnosti; B - Funkce vytvořená Alenou Buchtíkovou v rámci práce citované v podkapitole 4.4.; Analýza 3 - funkce vytvořená v podkapitole 5.3.3.; Celkové procento správné klasifikace = vážený průměr za předpokladu poměru obou skupin firem v české ekonomice, použitého v rámci celé práce (3:7). Odhad vychází z informací o podílu klasifikovaných úvěrů publikovaných ČNB (viz. pozn. 158)

Klasifikace vzorku pomocí výstupu Analýzy 3, provedené v programu Statistica, je ve všech ohledech optimističtější než výsledky dosažené dosazením hodnot ukazatelů do Altmanových funkcí. Hypotéza o omezené možnosti přenosu funkce z ekonomiky na ekonomiku tedy na základě tohoto srovnání nemůže být vyvrácena.

Jak je vidět z tabulky, je v případě použitého vzorku schopnost obou Altmanových funkcí rozeznávat české podniky v konkursu o mnoho lepší než jejich výkonnost při identifikaci prosperujících firem. Funkce tedy systematicky podhodnocují finanční stabilitu všech posuzovaných firem, a dopouštějí se tak relativně vyšší chyby  $\alpha$ . Na tuto vlastnost Altmanova skóre poukazují i výsledky předchozí aplikace ve finanční analýze českých podniků.<sup>227</sup> Pro zkušenost

<sup>225</sup> Jedná se o zopakování výsledků, jakých jsem dosáhla při testování klasifikační schopnosti funkce, zvolené na základě Analýzy 3, aplikací na sekundární data (viz tabulka 16).

<sup>226</sup> Funkce je výsledkem analýzy finančních výsledků klientů českých bank, provedené Buchtíkovou v roce 1998, a je uvedena v podkapitole 4.4.

<sup>227</sup> Např. Brynda (2000) ve své studii oceňování podniků odvětví plynárenství uvádí hodnoty obou výše popsaných typů Z-skóre pro osm distribučních společností - firem prosperujících a vítězem výběrového řízení na privatizaci českého plynárenství vysoce ohodnocených. Na základě spočtených hodnot Z skóre by však všechny tyto firmy až na jednu výjimku měly patřit do skupiny ztrátových podniků spějících ke krachu. Jedním z hlavních důvodů takového vychýlení hodnot Altmanova diskriminačního skóre je pravděpodobně způsob přijímání plateb zákazníků v oboru plynárenství: Zákazníci platí za spotřebu zálohově. V důsledku toho se tyto podniky jeví jako velmi zadlužené. Vzhledem k poměrně dobře odhadnutelné výši spotřeby v každém období (odhady jsou vytvářeny na základě spotřeby v minulosti) je však rozdíl mezi zálohou a ex post spočtenou

s popsaným podhodnocením výkonnosti je Altmanovo skóre v českých podmínkách používáno spíše v kontextu vzájemného porovnání v rámci odvětví. Průměr Altmanova skóre za dané odvětví v podobných analýzách určitým způsobem supluje hraniční čáru mezi obory hodnot Z. Další možné využití Altmanovy funkce při vědomí omezené přenositelnosti v prostoru a čase spočívá v pozorování vývoje hodnot za jednotlivé firmy v čase. Sestupný trend směrem od horní hranice podmnožiny oboru hodnot příslušející firmám spějícím k finančním potížím<sup>228</sup> může dát určitou informaci o hrozícím nebezpečí úpadku.

Další poznatek, který je důležitý z hlediska posouzení využitelnosti funkcí modelujících vztahy v americké ekonomice šedesátých a sedmdesátých let na podniky jiné ekonomiky doby méně vzdálené, může přinést porovnání výsledků dvou Altmanových funkcí mezi sebou. Vzhledem ke skutečnosti, že jsou ve vzorku obsaženy téměř výhradně neobchodované společnosti, lze očekávat, že funkce modelující finanční zdraví neobchodovaných společností (v tabulce označená jako „A2“) bude vykazovat lepší schopnost klasifikace než funkce modelující stav obchodovaných firem (označená „A1“). V případě zvoleného vzorku je tomu však právě naopak. Upravená funkce klasifikuje prosperující společnosti stejně jako funkce původní, společnosti problémové pak rozpoznává o něco hůře.

Před interpretací výsledků, jakých jsem dosáhla při klasifikaci podniků sekundárního vzorku pomocí funkce uvedené ve studii Aleny Buchtíkové,<sup>229</sup> bych ráda připomněla důležitou skutečnost, týkající se kritéria diskriminace. Autorka citované studie modelovala závislost skutečné platební disciplíny na poměrových ukazatelích. Naproti tomu sekundární data, která jsem měla k dispozici, byla rozlišena pomocí kritéria vyhlášení konkursu. Na tuto situaci se podle mého názoru může vztahovat úvaha, kterou jsem uvedla v rámci diskuse vhodnosti kritéria diskriminace zvoleného pro tuto práci:<sup>230</sup> Vzhledem k rozdílným definicím jednotlivých skupin není možné vyloučit vychýlení výsledků klasifikace kterýmkoli směrem. Výsledky použití funkce vytvořené na základě analýzy platební disciplíny vůči bance pro předpověď úpadku firmy hypotézu o možném vychýlení nevyvrátily. Funkce nerozpoznala žádnou firmu, na kterou byl v dalším období vyhlášen konkurs.

Uvedené výsledky porovnání výsledků modelů vytvořených v různém čase a prostoru nelze přirozeně vzhledem k velikosti testovacího souboru prohlásit za obecné. Test ani nebyl proveden za účelem znehodnocení výsledků předchozího výzkumu.<sup>231</sup> Uvedené srovnání však dle mého názoru pomáhá ilustrovat potenciální problémy, spojené s použitím funkce přinesené z vnějšku či z jiného období bez její předchozí adaptace na specifické podmínky. S podobnými problémy se může potýkat

---

fakturovanou částkou minimální – zadlužení je tedy skutečně spíše fiktivní. Myslím si, že podobné výjimky představují při přímé aplikaci Altmanova skóre nebezpečí.

<sup>228</sup> V případě Altmanovy původní funkce od hodnoty 1,81, v případě funkce upravené pro neobchodované společnosti pak od hodnoty 1,2.

<sup>229</sup> Buchtíková (1998).

<sup>230</sup> Viz sekce 5.2.1.1.

i banka, která používá model posuzování bonity převzatý od jiné finanční instituce či od firmy specializované na statistická šetření bez toho, aby ho průběžně podrobovala aktualizaci na změněné prostředí.

---

<sup>231</sup> Návrhy využití diskriminační funkce při vědomí jejího systematického podhodnocování jsou uvedeny výše v této pasáži.

## 6. ZÁVĚR

Cílem mé diplomové práce bylo přispět ke zkoumání možností systemizace posuzování míry úvěrového rizika pomocí metody vícerozměrné diskriminační analýzy. Jak jsem popsala, je modelování bonity pomocí MDA ve srovnání s interními modely založenými na ratingu, které doporučuje Basilejský výbor, z hlediska vstupních dat mnohem méně náročné. Diskriminační model měření úvěrového rizika je totiž ve formě, uvažované v rámci této práce, založen pouze na datech z účetních výkazů firem a na informaci o platební disciplíně každé firmy vstupního vzorku. Data z účetních výkazů,<sup>232</sup> která v modelu představují nezávisle proměnné, jsou bankám předkládána jako součást žádosti o úvěr. Finanční údaje o subjektech, které dosud banku o úvěr nepožádaly,<sup>233</sup> je možné získat z publikovaných výročních zpráv. Informaci o platební disciplíně, která v modelu představuje závisle proměnnou, mohly dosud banky získávat pouze u subjektů, kterým v minulosti poskytly nějaký úvěrový produkt. Prostor pro získávání informací tohoto typu bude podle mého názoru rozšířen přístupem do právě připravovaného registru klientských informací.<sup>234</sup> Omezená možnost získávat reprezentativní vzorky podniků, představující v současnosti obecnou překážku sledování významných závislostí, tak bude postupně odbourávána.

Rámec pro stěžejní část práce, vlastní studii závislosti finanční tísně na údajích z předchozích finančních výkazů, tvořil výklad možných úprav obecného modelu MDA podle rysů prostředí a zhodnocení stěžejních studií na toto téma. V rámci prvního zmíněného jsem se zaměřila zejména na zdůraznění vlastností MDA, které z ní činí flexibilní nástroj ohodnocování úvěrového rizika. Poukázala jsem na možnost zohlednění měnící se struktury klientů a nákladů různých chyb rozhodnutí. V části věnované zhodnocení dosavadních studií predikce finanční situace pomocí poměrových ukazatelů jsem poukázala na důležité limity aplikace výsledných funkcí v praxi. Uvažovala jsem omezení možnosti vytvoření univerzální funkce schopné předvídat finanční situaci firem operujících kdekoli v čase a prostoru, jako je například existence rozdílů v ekonomických podmínkách, které model popisuje, v dostupnosti a obsahu použitých ukazatelů apod.

Vyústěním výše shrnutých rozborů na teoretické rovině a dílčích obecných úvah byla vlastní empirická studie závislosti úpadku podniku na informacích z finančních výkazů, zařazená do druhé poloviny práce. Analýzy, provedené v jejím rámci, měly několik dílčích cílů. Vedle zjištění, do jaké míry lze finanční situaci českých podniků modelovat pomocí standardních

---

<sup>232</sup> V případě soukromých osob např. informace o příjmech uchazeče, jeho věku, vzdělání apod.

<sup>233</sup> Jak bylo uvedeno, uvažování pouze subjektů, které v minulosti banku o úvěr požádaly, je na úkor reprezentativnosti vzorku.

<sup>234</sup> V současné době jsou připravovány dva registry klientských informací – viz podkapitola 2.2.3.

statistických metod, mezi ně patřila především kvantifikace rozsahu již zvažovaných omezení vytvoření univerzální diskriminační funkce.

Analýzy<sup>235</sup> poukázaly na schopnost metody MDA vysvětlit finanční situaci českých firem pomocí informací z finančních výkazů za jedno období před pozorovaným stavem podniku. Analýza diskriminace podniků podle kritéria finanční situace<sup>236</sup> poukázala zejména na významnou závislost finanční tísně na ukazateli „míra zadlužení“ a na indikátorech „doba splatnosti dluhů“ a „doba splatnosti závazků“. Tento závěr je v souladu s očekáváním utvořeným na základě definice dlužníka v úpadku, zakotvené v Zákoně o konkursu a vyrovnání. Mezi dalšími proměnnými, jejichž vliv byl na základě analýz označen jako významný, je vedle rentability vlastního jmění a poměru pracovního kapitálu také proměnná, která nepatří mezi standardní poměrové ukazatele. Je jí indikátor „zatíženost hmotného investičního majetku“, spočtený jako poměr HIM, na který bylo z důvodů vstoupení do různých dlužnicko-věřitelských vztahů uvaleno břemeno zástavního práva, a celkového hmotného investičního majetku.<sup>237</sup> V této proměnné je přirozeně ztělesněna míra zadlužení společnosti; vypořádaný vliv na finanční tíseň tedy bylo možné rovněž očekávat. Ráda bych zde však upozornila na jiný rozměr této proměnné. Skutečnost, že u podniků v konkursu tato proměnná nabývala i hodnot přesahujících logickou hranici 1, dává totiž této proměnné další obsah, spočívající v upozornění na manipulaci s údaji či nepřehlednou politiku vstupování do rolí dlužníka vůči různým věřitelům. Významnost vlivu této proměnné, vypořádaného v rámci výše uvedených analýz, může být varovným signálem o netransparentnosti prostředí, ve kterém se podniky a banky pohybují.

Výsledky, jakých jsem dosáhla při klasifikaci sekundárních dat pomocí funkcí modelujících výše popsané závislosti, byly ve srovnání s výsledky předchozích studií na toto téma velmi povzbudivé. Relativně nízká klasifikační schopnost referenčních modelů vytvořených na datech charakterizující jiný prostor, respektive čas, navíc mluvila ve prospěch hypotézy o omezené přenositelnosti funkcí.

Analýzy provedené v rámci této práce dále poukázaly na stírání rozdílů mezi jednotlivými skupinami podniků při pohledu dále do minulosti před pozorovaným stavem firmy. Takový výsledek je pravděpodobně důsledkem postupného vývoje každé firmy, v jehož průběhu mohou být období vysoké prosperity střídána obdobími charakterizovanými sníženou platební schopností. Pozorované změny struktury dat v čase přispěly ke zpochybnění implicitního

---

<sup>235</sup> Výsledky všech analýz jsou shrnuty v Příloze 4.

<sup>236</sup> Kritérium finanční situace (vyhlášení konkursu versus prosperita) jsem použila z důvodů nedostupnosti informací o platební morálce jednotlivých firem. Vztahy, které jsem na základě vlastních analýz vypořádovala, se proto mohou od vztahů významných pro bankovní praxi lišit jak kvalitativně, tak kvantitativně. V podkapitole 5.2.1.1. jsem diskutovala možné vychýlení výsledného modelu v důsledku aproximace platební morálky finanční tísní.

<sup>237</sup> Viz pasáž 5.2.2.1.4.

předpokladu, na němž se zakládá většina předchozích studií na toto téma,<sup>238</sup> a to předpokladu shodnosti koeficientů příslušejících v čase posunutým proměnným. Potvrzení zpochybnění tohoto předpokladu dalšími studii může podle mého názoru představovat pro banky poměrně silnou motivaci pro neustálé sledování měnící se struktury klientů a průběžnou adaptaci interních modelů měření úvěrového rizika podle pozorovaných změn.

V rámci práce jsem odkryla několik námětů pro případné další studie možnosti modelování finanční tísně. Patří mezi ně zkoumání možností využití metod umělé inteligence či rozhodovacích stromů, dále pak analýza rozšířeného vzorku dat zaměřená na vytipování ukazatelů upozorňujících na finanční tíseň s předstihem delším než jedno období, či přidání zkoumání proměnných popisujících strukturu odvětví, existenci restrikcí apod. Domnívám se, že dílčí poznatky o možnostech využití MDA pro predikci platební schopnosti, ke kterým jsem dospěla na základě analýz provedených v rámci této práce, mohou být kombinací se závěry takových studií ověřeny, popřípadě dále zhodnoceny.

---

<sup>238</sup> Např. Altman (1968) nebo Sinkey (1975).

## POUŽITÁ LITERATURA

- Afifi, A. A., Clark V., Computer-Aided Multivariate Analysis, Van Nostrand Reinhold, 1990
- Altman, E. I., Caouette, J. B., Narayanan, P., Managing Credit Risk, John Wiley and Sons, 1998
- Altman, E. I., Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy, Journal of Finance, Volume 23, Issue 4 (Sep., 1968), 589-609
- Anderson, T. W., Introduction to Multivariate Statistical Analysis, John Wiley and Sons, Inc., 1958
- Anderton, B., Current Issues in Financial Services, Macmillan, 1995
- Brealey, R. A., Myers, S. C., Teorie a praxe firemních financí, East Publishing, 1999
- Brynda, P., Privatizace českého plynárenství, IES FSV UK, 2000
- Buchtíková, A., Empirická analýza financování podniků a úvěrových aktivit bank v ČR v letech 1995-1997, Měnová sekce ČNB, 1999
- Buchtíková, A., Mikroekonomické aspekty transmisního mechanismu měnové politiky v úvěrovém kanále (empirická studie), Měnová sekce ČNB, 2001
- Buchtíková, A., Příspěvek k hodnocení finanční bonity bankovních klientů, ČNB, 1998
- Campbell, J. Y., Lo, A. W., MacKinlay, A. C., The Econometrics of Financial Management, Princeton University Press, 1997
- Derviz, A., Kadlčáková, N., Methodological Problems of Quantitative Credit Risk Modeling in the Czech Economy, Měnová sekce ČNB, 2001
- Eisenbeis, R. A., Pitfalls in the Application of Discriminant Analysis in Business, Finance, and Economics, The Journal of Finance, June 1977
- Fabozzi, F. J., Bank Loans: Secondary Market and Portfolio Management, Frank J. Fabozzi Associates, 1998
- Heffernan, S., Modern Banking in Theory and Practice, John Wiley and Sons, 1996
- Judge, G. G., Griffiths, W.E., Hill, R.C., Lütkepohl, H., Lee, T.-C.; The Theory and Practice of Econometrics, John Wiley and Sons 1985
- McLachlan, G., Discriminant Analysis and Statistical Pattern Recognition, John Wiley and Sons, Inc. 1992
- Mejstřík, M., Dvořáková, A., Neprašová, M., Restructuring and Development of the Banking sector in Advanced Transition Countries: Czech Republic, IES FSV UK, 2002
- New Basle Capital Accord – návrh Nové basilejské dohody, dostupný na [www.bis.org](http://www.bis.org).
- Pokutová, S., Struktura, výkonnost a efektivnost českého bankovního sektoru, IES FSV UK, 2002

- Price Waterhouse, Úvod do řízení úvěrového rizika, Management Press, 1992
- Puri, M. L., Sen, P. K., Nonparametric Methods in Multivariate Analysis, John Wiley and Sons, Inc., 1971
- Seger, J., Hindls, R., Hronová, S.; Statistika v hospodářství, ETC Publishing, 1998
- Sekerka, B., Řízení bankovních rizik, Profess Consulting, 1998
- Sinkey, J. F. Jr., Commercial Bank Financial Management, Macmillan, 1992
- Sinkey, J. F., Jr., A Multivariate Statistical Analysis of Characteristics of Problem Banks, The Journal of Finance, March 1975
- Sjøvoll, E., Assessment of Credit Risk in the Norwegian Business Sector, Norges Bank, 1999
- Zákon č. 328/1991 Sb., O konkurzu a vyrovnání, ve znění pozdějších předpisů
- Zpráva o činnosti bankovního dohledu v České republice, ČNB, 1999



## **TEZE DIPLOMOVÉ PRÁCE**



## **PŘÍLOHY**

- Příloha I      Hodnoty proměnných použitých pro analýzy prezentované v podkapitole 5.3
- Příloha II      Korelace mezi proměnnými
- Příloha III     Shrnutí výsledků jednotlivých analýz
- Příloha IV     Výsledky klasifikace primárních dat pomocí funkcí zvolených na základě vlastních analýz
- Příloha V      Výsledky klasifikace sekundárních dat pomocí funkcí zvolených na základě vlastních analýz a pomocí funkcí zvolených autory referenčních studií
- Příloha VI     Grafy rozdělení nezávisle proměnných