

Finanční ukazatele jako faktory predikce finanční tísně pro SME v ČR

Jan Adamec

Abstract: *Malé a střední podniky vyžadují vlastní přístup při vytváření modelů predikce finanční tísně, protože se významně liší od velkých společností. Cílem této práce je kvantifikovat predikční schopnost vybraných ukazatelů a vytvořit model predikce finanční tísně. Statistickými metodami bylo testováno 16 ukazatelů na souboru 1563 malých a středních firem. Výsledný model zahrnuje ukazatel pohotové likvidity, doby obratu pohledávek, výše zadlužení, podílu vlastního kapitálu a ukazatel krytí úroků nebo dluhů z běžného cash flow. Výsledek této práce potvrzuje, že finanční tíseň úzce souvisí se schopností firmy hradit své dluhy. Ukazatele ziskovosti nebyly identifikovány jako rozhodující faktory v krátkém období, což ukazuje na komplikovanější vztah mezi ziskem a platební kapacitou firmy. Jako významný ukazatel byl identifikován běžný peněžní tok, který těsněji souvisí s peněžními prostředky společnosti.*

Klíčová slova: SME finance · Modeling úvěrového rizika · Finanční analýza · Predikce finanční tísně

JEL Classification: G32 · G33 · C35

1 Úvod

Výzkum směřující k identifikaci předstihových ukazatelů finanční tísně podniku je předmětem zájmu vědců, podnikatelské sféry i regulátorů dohlížejících na fungování bankovního systému. V současnosti je přístup vědy ke zkoumání predikce finanční tísně malých a středních podniků, tzv. small and medium enterprises (SME) více komplexnější a konzistentnější oproti předchozím obdobím. Důvodem zájmu o tyto společnosti je, že tvoří dominantní podíl ekonomických podnikatelských subjektů v tržní ekonomice a jsou významným zdrojem zaměstnanosti. Pozitivně se v ekonomice projevuje jejich schopnost rychlé reakce na tržní podmínky. Výzkumy a praxe potvrzují, že tyto podniky jsou rozdílné od velkých společností a je nutno k těmto subjektům zvolit samostatný přístup. U modelů odvozených na základě dat o velkých společnostech se snižuje jejich prediktivní schopnost při použití na dělenmalé a střední podniky. Hlavním cílem tohoto příspěvku je zhodnotit schopnost predikce finanční tísně (resp. defaultu) na základě finančních ukazatelů získaných z účetních výkazů. Celkem bylo zkoumáno 16 ukazatelů a použita byla logistická regresní analýza.

2 Přehled literatury

Jak uvádí Aquino (2010), výzkum účetních informací k predikci finanční tísně a bankrotu firem probíhá od druhé poloviny 19. století a největšího pokroku bylo dosaženo od konce šedesátých let 20. století do počátku nového tisíciletí, kdy nové postupy byly aplikovány v dohodě Basel II, která zahrnuje požadavky na kapitálovou přiměřenost bank. Za nejdůležitější práce posledních 45 let Aquino uvádí výzkum Beaver (1966), Altman (1968), Ohlson (1980), Altman, Sabato a Wilson (2010).

Ing. Jan Adamec

Jihočeská univerzita v Českých Budějovicích, Ekonomická fakulta, Katedra účetnictví a financí, Studentská 13, 370 05 České Budějovice, e-mail: adamecjan@centrum.cz.

Beaver rozpracoval jednorozměrnou analýzu, kdy zkoumal schopnost 30 účetních ukazatelů predikovat finanční tíseň podniku. U jednotlivého ukazatele stanovil hranici, která rozlišovala mezi dobrými a špatnými firmami s cílem dosáhnout co nejmenší chyby, zkoumal tzv. error I (špatná firma klasifikována jako dobrá) a error II (dobrá firma klasifikována jako špatná). Následnou průkopnickou prací v oblasti statistických přístupů k problematice předpovědi finanční tísně je práce Altmana. Altman použil vícerozměrnou diskriminační analýzu (MDA), při které zkombinoval několik ukazatelů. Tento přístup byl následně kritizován pro časté porušování základních předpokladů pro možnost použití lineární diskriminační analýzy (homogenita kovariačních matic predikátorů pro defaultní i nedefaultní firmy a dále normální rozdělení těchto predikátorů). Výchoiskem byl přístup Ohlsona, který použil k řešení problému logistický model, který není omezen restrikcemi kladenými na MDA. Významné práce využití MDA v podmínkách České a Slovenské republiky byly rozpracovány autory Neumaier a Neumaierová (2005), Gurčík (2002), testování modelů na zemědělských podnicích podnikl Kopta (2006).

S přípravou Basel II byla velká pozornost věnována metodologii testování výsledků jednotlivých modelů. Významnou prací v tomto ohledu je práce Sobehart, Keenan a Stein (2000), kde je rozpracována metodika ratingové agentury Moody's (definuje křivku Cumulative Accuracy Profiles - CAP a ukazatel Accuracy Ratio - AR), která umožňuje komplexní pohled na error I a error II jednotlivých modelů. Na tuto práci dále navazuje práce Engelmann, Hayden a Tasche (2003), která dále rozpracovává měření diskriminační síly ratingových modelů a dokazuje ekvivalentnost mezi přístupem Moody's a křivkou Receiver Operating Characteristic Curve (ROC) a ukazatelem Area Under ROC Curve (AUC), kdy tato metodika je používána mnoho let zejména v oblasti medicíny. Komplexní metodika zpracování ratingového modelu dle Basel II byla publikována Rakouskou národní bankou (2004), touto metodikou se zabývá i český autor Witzany (2010).

Výzkum zaměřený na malé a střední podniky (SME) publikoval Altman a Sabato (2006), kteří vytvořili model na základě zkoumání účetních výkazů SME v USA, kde se jednalo o firmy s vyšší obrátou do 65 mil. USD a moment defaultu byl definován bankrotem společnosti v letech 1994-2002. V jejich modelu je 5 následujících ukazatelů: i) peníze/aktiva, ii) EBITDA/aktiva, iii) EBITDA/úroky, iv) zadržené zisky/aktiva, v) krátkodobé dluhy/VK. Altman, Sabato a Wilson (2010) tento model zkoumali na firmách Velké Británie a výzkum dále rozšířili o analýzu kvalitativních ukazatelů, díky kterým dosáhli vyšší prediktivní síly modelu.

3 Materiál a metodika

Metodika této práce vychází z pravděpodobnostního přístupu k hodnocení bonity podniků zpracovaného Ohlsonem (1980), který navázal na předchozí výzkumy započaté I. A. Altmanem v oblasti použití lineární diskriminační analýzy. K využití této metody však kritici vznášejí námitky zejména s ohledem na předpoklady tohoto modelu, které je nutno dodržet.

Pro analýzu defaultu současná věda preferuje použití logistické regresní analýzy, protože při zkoumání defaultu pracujeme s binární vysvětlovanou proměnnou Y , která s pravděpodobností π nabývá hodnot 1 a s pravděpodobností $(1 - \pi)$ hodnoty 0. Použití logistické regresní funkce nám zajišťuje, že výsledek nabývá hodnot v intervalu od 0 do 1, přestože funkce $x'b$ (bližze vzorce 1, 2, 3) může nabývat libovolných hodnot. Zároveň logistická regrese opouští lineární vztah mezi vysvětlující a vysvětlovanou proměnnou, který není pro zkoumání finanční tísně zcela vhodný, protože v realitě nebývá lineární vztah mezi vysvětlující proměnnou a pravděpodobností finanční tísně (defaultu). Např. růst zadlužení při nízké míře zadlužení nemá stejný dopad do růstu rizika jako menší růst zadlužení při vysokém zadlužení. Řešíme otázku, jaká je pravděpodobnost, že firma s určitým finančním profilem nebude schopna dostát svým závazkům. Předpoklady tohoto modelu nepožadují homogenitu kovariačních matic ani normální rozdělení proměnných.

Základní předpoklady logistické regresní analýzy:

- pro každou skupinu (defaultní a nedefaultní firmy) je nutné mít větší počet pozorování než počet nezávisle proměnných;

- není přípustná multikolinearita, resp. je nutno ji testovat, zda negativně neovlivňuje výsledky;
- nepoužívat proměnné s častými chybějícími hodnotami;
- nepřítomnost odlehlých pozorování.

Regresní funkce s tzv. logitovou transformací π je definována funkcí (1), kde vektor x' vyjadřuje v našem případě charakteristiku podniku (finanční ukazatele) a vektor b regresní koeficienty. Logitová transformace nám umožňuje model linearizovat, zde vyjádřeno vztahem $x'b$

$$g(\pi) = \ln \frac{\pi}{1-\pi} = x'b, \quad (1)$$

kde $x' = [1, x_1, x_2, \dots, x_k]$, $b = [b_0, b_1, \dots, b_k]$.

Uvedenou rovnici (1) můžeme matematickou úpravou přepsat do tvaru rovnice (2)

$$\frac{\pi}{1-\pi} = e^{x'b} \quad (2)$$

a další úpravou získáme vztah (3), ze kterého je lépe patrné, že funkce $x'b$ může nabýt jakýchkoli hodnot, zatímco výsledek π nabývá hodnot v rozmezí 0 až 1.

$$\pi = \frac{e^{x'b}}{1+e^{x'b}} = [1 + e^{-x'b}]^{-1} = \frac{1}{1+e^{-x'b}} \quad (3)$$

V našem případě výstupem funkce (3) je skóre, jehož schopnost diverzifikovat mezi zdravými a nezdravými firmami nám umožňuje zkoumat Cumulative Accuracy Profile (CAP). Ze statistického pohledu tato křivka znázorňuje vývoj kumulativní distribuční funkce pravděpodobnosti výskytu defaultu pro různé výše percentilu skóre firem. Tato křivka nám umožňuje zobrazit Error I a Error II zároveň pro všechny hodnoty skóre. Při výpočtu jsou nejprve společnosti seřazeny podle výše skóre od nejrizikovějšího k nejméně rizikovému, k danému procentu všech firem je poté vypočítáno procento defaultních firem, které jejich skóre správně identifikovalo jako defaultní. V případě dokonalého modelu křivka CAP roste rychle vzhůru, protože takový model by nejprve identifikoval všechny defaultní firmy. Například pokud by vzorek obsahoval 13 % defaultních firem, pak v případě dokonalého modelu, by v 13 % procentech firem s nejhorším skóre bylo obsaženo 100 % defaultních firem a žádné nedefaultní. U náhodného modelu by naopak v 13 % procentech firem s nejhorším skóre bylo obsaženo 13 % defaultních firem. Výhodou CAP křivky je, že poskytuje informaci o prediktivní síle modelu pro všechna skóre. Error I je vertikální přímkou od CAP křivky ratingového modelu k přímkou dokonalého modelu a Error II je zjednodušeně definováno horizontální přímkou od CAP křivky ratingového modelu k bodu, který leží mezi osou y a křivkou CAP dokonalého modelu a musí být poměřována s nedefaultními firmami (osa x obsahuje všechny firmy).

Kvalitu modelu správně diverzifikovat mezi firmami měříme pomocí Accuracy ratio, jehož definice je uvedena v rovnici (4). Tento ukazatel je definován jako poměr mezi plochou aR , která zahrnuje plochu mezi křivkou CAP ratingového modelu a náhodného modelu, a plochou aP , která zahrnuje plochu mezi křivkou CAP dokonalého modelu a náhodného modelu.

$$\text{Accuracy ratio} = \text{GINI} = \frac{aR}{aP} \quad (4)$$

Další rozšířenou metodou zkoumání prediktivní schopnosti modelu je přístup Receiver Operating Characteristic Curve (ROC) a ukazatele Area Under ROC Curve (AUC). Tato křivka zobrazuje na ose y hit rate, tj. procento správně předpovězených defaultů a na ose x false alarm, tj. procento nedefaultních firem označených jako defaultní pro všechna skóre. Vztah mezi AR a AUC definuje následující rovnice:

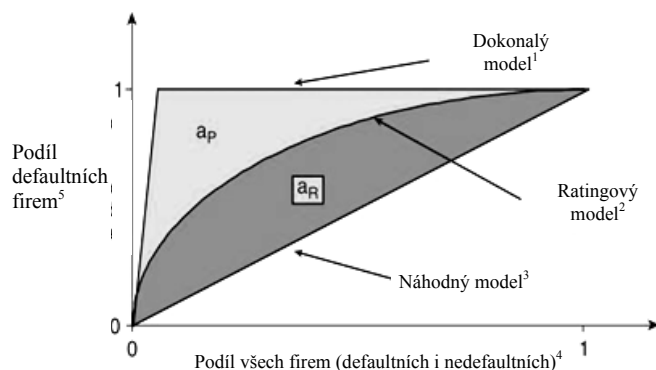
$$\text{Accuracy ratio} = 2 (AUC - 0,5) \quad (5)$$

Tato práce se zabývá analýzou možnosti hodnocení bonity společnosti výhradně na základě finančních výkazů, kdy primárně je zaměřena na menší a střední společnosti, u kterých lze předpokládat nižší predikční schopnost oproti často testovaným velkým korporacím. Při analýze

jsme omezeni vypovídající schopností českého účetnictví. Pro vybudování modelu byl použit reprezentativní vzorek firem, což umožnilo využít statistické procedury.

Obrázek 1 Cumulative accuracy profile (CAP)

Figure 1 Cumulative accuracy profile (CAP)



Zdroj: Engelmann, Hayden, Tasche (2003)

Source: Engelmann, Hayden, Tasche (2003)

Notes: ¹Perfect model, ²Rating model, ³Random model, ⁴Fraction of defaulted companies, ⁵Fraction of all companies.

Statistickému zkoumání byl podroben vzorek obsahující finanční data o 1.563 českých SME výrobních a nevýrobních firmách s velikostí obrátu do 400 mil. Kč. Z tohoto vzorku bylo 203 firem označeno jako defaultní. Nedefaultní firmy byly vybrány náhodným výběrem z portfolia za stejné období jako defaultní, jedná se o defaulty, které se udály v letech 2000 až 2005. Procento defaultu vzorku (cca 13 %) neodpovídá procentu defaultu původního portfolia, toto nadhodnocení je však nutné pro vytvoření modelu. Tento rozdíl je následně při tvorbě ratingového modelu kalibrován na tzv. centrální tendenci, resp. na průměrnou dlouhodobou rizikovost portfolia v průběhu ekonomického cyklu (Through The Cycle, TTC), kterého doporučována délka je 5 let. Pojem default je definován dle obecně používané metodiky Basel II a návazné direktivy EU:

- úvěrová instituce vyhodnotila, že dlužník pravděpodobně nebude schopen plně uhradit své úvěrové závazky bez nutnosti získání prostředků z jiných zdrojů, např. zpeněžením zajištění (bankrot firmy je pouze částí takovýchto firmem, tato definice je širší a zahrnuje např. i nutnost restrukturalizace dluhu a více odpovídá finanční tísní firmy);
- nebo dlužník je po splatnosti déle než 90 dnů.

Dále k definování defaultu je použit skupinový přístup, tzv. Cohort Approach. Tzn. pozorovacím obdobím je 1 rok, od 1.1. do 31.12., během tohoto období se u firmy může vyskytnout default nebo nemusí. K vytvoření modelu jsou pak používány konečné celoroční finanční výkazy, které byly k dispozici před tzv. pozorovacím obdobím, např. default nastal 5.4.2004, k začátku pozorovacího období 1.1.2004 byly k dispozici výkazy k 31.12.2002. Výkazy k 31.12.2003 nejsou používány, protože jsou příliš blízko okamžiku defaultu a nejsou tak vhodné pro model predikce, a zároveň je nutno uvažovat zpoždění mezi účetním dnem, vytvořením výkazu a jejich zveřejněním či poskytnutím finanční instituci.

Velikost obrátu firem odpovídá tomu, že předmětem zkoumání jsou firmy SME, tzn. malé a střední firmy, jako hranice byl zvolen obrát 400 mil. Kč, přičemž většina firem ze vzorku má obrát do 100 mil. Kč. Tato hranice byla zvolena s ohledem na podnikatelskou strukturu naší ekonomiky

a dále zvyklost v ČR. V rámci Basel II je za SME firmu považována společnost až do obrátu 50 mil. EUR.

Tabulka 1 Přehled členění souboru dat
Table 1 Structure of data sample by year


Rok ¹	Počet firem ²	Počet defaultů ³
2000	63	47
2001	142	37
2002	299	40
2003	81	24
2004	581	29
2005	397	26
Celkem ⁴	1563	203

Zdroj: vlastní výzkum

Source: own research

Notes: ¹ Year, ² Number of firms, ³ Number of defaults, ⁴ Total.

Obrázek 2 Struktura zkoumaného vzorku dle obrátu
Figure 2 Structure of data sample by turnover



Zdroj: vlastní výzkum

Source: own research

U jednotlivých finančních ukazatelů byly na základě jednofaktorové analýzy analyzovány krajní hodnoty ukazatelů, což umožnilo stanovit maximální a minimální hodnoty, které ještě přispívají k vysvětlení pravděpodobnosti defaultu a eliminovat odlehlá pozorování.

Finanční ukazatele byly následně standardizovány na medián 0 a směrodatnou odchylku 1 k dosažení symetrické distribuce jednotlivých ukazatelů. Standardizace probíhá způsobem, kdy od každé hodnoty je nejprve odečten medián a tento rozdíl je vydělen směrodatnou odchylkou

$$y = \frac{x - \mu}{\sigma}, \quad (6)$$

kde μ = medián výběru, σ = směrodatná odchylka výběru, x = ukazatel před standardizací.

Přestože toto není podmínkou použití logistické regrese, je symetrické rozdělení doporučováno, jelikož následně můžeme výsledné koeficienty vícerozměrné analýzy interpretovat jako váhy jednotlivých faktorů. Vztah mezi finančním ukazatelem byl v některých případech upraven změnou znaménka tak, aby čím je jeho hodnota nižší, tím vyšší byla pravděpodobnost výskytu defaultu. Tato úprava se týká ukazatelů doby obrátu pohledávek, zásob a doby splatnosti závazků.

4 Výsledky

Pomocí logistické regrese byla odvozena kombinace finančních ukazatelů, která má co největší schopnost detekovat v předstihu výskyt defaultu jakožto negativního jevu. K odvození modelu bylo zkoumáno 16 finančních ukazatelů, které jsou uvedené v následující tabulce. Koeficient Accuracy ratio (AR, blíže vzorec 4) měří sílu jednotlivého ukazatele rozlišovat mezi defaultní a nedefaultní firmou a byl spočítán pro každý ukazatel na celém souboru dat.

Tabulka 2 Přehled zkoumaných ukazatelů a jejich AR koeficient
Table 2 Survey of tested financial ratios and their calculated AR

Kód ¹	Název finančního ukazatele ²	Skupina ³	Míra přesnosti ⁴
R2	Marže přidané hodnoty ⁵	Rentabilita ⁶	13 %
R5	Rentabilita tržeb ⁷	Rentabilita ⁶	15 %
R6	Marže běžného cash flow ⁸	Rentabilita ⁶	26 %
R7	Rentabilita vlastního kapitálu ⁹	Rentabilita ⁶	24 %
R11	Rentabilita aktiv ¹⁰	Rentabilita ⁶	22 %
L3	Rychlá likvidita ¹¹	Likvidita ¹²	32 %
L5	Běžná likvidita ¹³	Likvidita ¹²	31 %
L7	Doba obratu zásob ¹⁴	Aktivita ¹⁵	10 %
L9	Doba inkasa pohledávek ¹⁶	Aktivita ¹⁵	11 %
L10	Doba splatnosti závazků ¹⁷	Aktivita ¹⁵	25 %
F2	Podíl vlastního kapitálu včetně závazků ve skupině ¹⁸	Kapitálová struktura ¹⁹	36 %
F6	Zadluženost ²⁰	Kapitálová struktura ¹⁹	34 %
D2	Krytí dluhů běžným cash flow ²¹	Schopnost splácet ²²	29 %
D4	Krytí dlouhodobých dluhů běžným cash flow ²³	Schopnost splácet ²²	22 %
D6	Krytí úroků ze zisku ²⁴	Schopnost splácet ²²	25 %
D8	Krytí úroků z běžného cash flow ²⁵	Schopnost splácet ²²	29 %

Zdroj: vlastní výzkum

Source: own research

Notes: ¹Code, ²Financial ratio, ³Group, ⁴Accuracy ratio, ⁵Value added margin, ⁶Rentability, ⁷Return on sales, ⁸Current cash flow margin, ⁹Return on equity, ¹⁰Return on assets, ¹¹Quick ratio, ¹²Liquidity, ¹³Current ratio, ¹⁴Inventory turnover time, ¹⁵Activity, ¹⁶Receivables turnover time, ¹⁷Liabilities turnover time, ¹⁸Solvency – subordinated debt, ¹⁹Capital structure, ²⁰Leverage, ²¹Debt coverage from CCF, ²²Repayment capacity, ²³Long term debt coverage from CCF, ²⁴Interest coverage, ²⁵Int. cov. from Current cash flow.

Problémem při vytváření vícerozměrného modelu je vzájemná korelace mezi jednotlivými vysvětlujícími proměnnými, proto musíme výsledky statisticky testovat. Pro další analýzu a možnost testování prediktivní síly výsledné funkce byl vzorek firem rozdělen v poměru 70 % pro odvození modelu (952 nedefaultních firem a 142 defaultních firem) a 30 % jako testovací vzorek.

Pro statistické výpočty byl použit software STATISTICA. Forward stepwise analysis, na 1% hladině spolehlivosti vybral ukazatele L3, F6, L9 a na 5% hladině spolehlivosti L3, F6, L9 a D8. Analýza backward stepwise analysis po vyloučení R5 a R11, protože tyto ukazatele se ve výsledné funkci chovaly nelogicky (čím vyšší rentabilita, tím vyšší pravděpodobnost defaultu), na 5% hladině významnosti vybrala stejné ukazatele jako forward stepwise analysis. Analýza na základě nejlepších podskupin indikovala v případě 4 ukazatelů výše uvedenou kombinaci ukazatelů, v případě 5 ukazatelů navrhla přidat F2 a dále možnost zaměnit D8 za D2.

Vybrané faktory pro predikci finanční tísně:

- Rychlá likvidita (L3)
- Zadluženost (F6) - (VK – pohledávky za upsaný kapitál – dlouhodobá nehmotná aktiva – oceňovací rozdíly – odložené daně) / (bankovní úvěry a půjčky + leasingové závazky)
- Doba inkasa pohledávek (L9).

$$\text{Výsledná funkce: } \ln \frac{\pi}{1-\pi} = -2,453 - 0,605 L3 - 0,397 F6 - 0,375 L9 \quad (7)$$

Do modelu není možné zadávat přímo hodnoty jednotlivých ukazatelů, ale musí být nejprve transformována na základě dat v Tabulce 3, kde jsou uvedeny potřebná data ke stanovení dolních a horních hranic, dále informace k provedení standardizace a případné změny znaménka.

Tabulka 3 Transformace dat

Table 3 Transformation parameters

	Dolní hranice ¹	Horní hranice ²	Medián ³	Směrodatná odchylka ⁴	Změna znaménka ⁵
L3	0,1	1,2	0,863	0,331	Ne ⁶
F6	-0,2	1	1,000	0,356	Ne
L9	10	130	45,445	33,483	Ano ⁷

Zdroj: vlastní výzkum

Source: own research

Notes: ¹Low cut-off, ²Hi cut-off, ³Median, ⁴Standard deviation, ⁵Reverse, ⁶No, ⁷Yes.

Tabulka 4 Wald test

Table 4 Wald test

	Odhad ²	Wald. - Stat.	Dolní LS - 95, % ³	Horní LS - 95, % ⁴	P
Abs. člen ¹	-2,45304	359,6896	-2,70655	-2,19954	0,000000
L3	-0,60548	35,5514	-0,80451	-0,40645	0,000000
F6	-0,39726	24,8767	-0,55337	-0,24115	0,000001
L9	-0,37446	16,2440	-0,55656	-0,19236	0,000056

Zdroj: vlastní výzkum

Source: own research

Notes: ¹Absolute member, ²Estimate, ³Low cut-off, ⁴Hi cut-off.

Znaménka všech koeficientů vyšla správně záporná a jdou ve stejném směru, protože všechny hodnoty před statistickým zpracováním byly upraveny tak, aby jejich nižší hodnota znamenala vyšší pravděpodobnost defaultu. Wald testem zkoumáme, zda je parametr v rámci funkce nula nebo ne. Wald test v souladu s předchozí analýzou potvrdil statistickou významnost uvedených faktorů. Také statistika -2LL (-2 log likelihood) vyšla jako statisticky významná s hodnotou 749. Tento test je obdobou F-testu z lineární regrese a pomáhá nám testovat, zda všechny parametry dohromady dokáží predikovat závisle proměnnou. Vyšší hodnota indikuje horší predikci závisle proměnné. Výsledek Hosmer-Lemeshow testu dobré shody dosáhl hladiny významnosti $p = 0,11$, což znamená, že při hladině významnosti 0,05 nezamítáme nulovou hypotézu, že mezi pozorovanými a modelem predikovanými hodnotami není žádný rozdíl.

Na modelovém vzorku bylo dosaženo Accuracy ratio (AR) 48,6 % (alternativně můžeme sílu modelu vyjádřit plochou pod ROC křivkou, která je součástí programu STATISTICA, kterou označujeme AUC, tato dosáhla 74 %). Odvozený model byl otestován na záložním vzorku, který jsme nepoužili k odvození modelu. Na testovacím out of sample vzorku dosáhl AR výše 42,9 % (plocha pod ROC křivkou 71 %). Funkce vykázala slabší výsledky na záložním vzorku. Rozšíříme model o další parametr, který by měl přinést větší sílu modelu i na záložním vzorku.

Jako statisticky významný i jako logicky vhodný se jeví parametr D8.

– Krytí úroků z běžného cash flow

(běžné cash flow + daň + úroky) / úroky

Po přidání tohoto parametru získáme novou výslednou funkci:

$$\ln \frac{\pi}{1-\pi} = -2,423 - 0,550 L3 - 0,354 F6 - 0,339 L9 - 0,262 D8 \quad (8)$$

Tabulka 5 Transformace dat

Table 5 Transformation parameters

	Dolní hranice ¹	Horní hranice ²	Medián ³	Směrodatná odchylka ⁴	Změna znaménka ⁵
D8	0	10	5,654	3,199	Ne ⁶

Zdroj: vlastní výzkum

Source: own research

Notes: ¹ Low cut-off, ² Hi cut-off, ³ Median, ⁴ Standard deviation, ⁵ Reverse, ⁶ No.**Tabulka 6** Wald test

Table 6 Wald test

	Odhad ²	Wald. - Stat.	Dolní LS - 95, % ³	Horní LS - 95, % ⁴	P
Abs.člen ¹	-2,42255	348,3383	-2,67695	-2,16815	0,000000
L3	-0,54957	28,0752	-0,75286	-0,34628	0,000000
F6	-0,35385	18,7894	-0,51384	-0,19385	0,000015
L9	-0,33884	12,9545	-0,52335	-0,15432	0,000319
D8	-0,26223	6,2188	-0,46833	-0,05613	0,012640

Zdroj: vlastní výzkum

Source: own research

Notes: ¹ Absolute member, ² Estimate, ³ Low cut-off, ⁴ Hi cut-off.

Znaménko nově přidaného koeficientu je správné a v souladu s předchozími. Wald test potvrzuje nenulovou hodnotu koeficientů. Statistika -2LL (-2 log likelihood) vyšla statisticky významná se skóre 743, zamítáme tak nulovou hypotézu, že regresní koeficienty se rovnají nule. Test Hosmer-Lemeshow dosáhl hladiny významnosti = 0,69. Nezamítáme tedy hypotézu, že mezi pozorovanými a predikovanými hodnotami není rozdíl. Hodnota AR dosáhla 48,2 % (plocha pod ROC, kterou označujeme AUC dosáhla 74 %). Otestujeme nyní jeho výkonnost na záložním vzorku. Accuracy ratio na tomto vzorku dosáhlo 46,5 % (AUC 73 %) a model tak prokázal větší prediktivní sílu. Tento model dosáhl obdobného výsledku na vzorku, ze kterého byl odvozen model i na datech záložního vzorku. Přidání nového faktoru vede ke zlepšení kvality modelu a výsledky síly modelu jsou více stabilní. Následující Tabulka 7 dokládá korelační koeficienty mezi jednotlivými vysvětlujícími proměnnými. U tohoto modelu vzájemná korelace ukazatelů je na přijatelných úrovních.

Následující Obrázek číslo 3 nám vykresluje průběh křivky CAP s Accuracy ratio 48,2 %. Čárkovaná čára představuje náhodný model, který není schopen rozlišit mezi defaultními a nedefaultními firmami, naopak tečkovaná čára vyznačuje dokonalý model. Vytvořený model představuje tučná čára. Čím je model z počátku strmější, tím je zpravidla pokládán za lepší.

Tabulka 7 Korelace

Table 7 Correlation

	L9	F6	L3	D8
L9	1,00	0,01	-0,2	0,09
F6	0,01	1,00	0,32	0,26
L3	-0,2	0,32	1,00	0,25
D8	0,09	0,26	0,25	1,00

Zdroj: vlastní výzkum

Source: own research

CAP křivka znázorňuje error I (špatná firma klasifikovaná jako dobrá) a error II (dobrá firma klasifikovaná jako špatná) pro všechna možná cut off skóre. Posunem po křivce dochází k trade-off mezi error I a error II. Při stanovení cut off skóre na úrovni percentilu 30 %, tj. skóre 0,141, vychází error I ve výši 37,3 % a error II ve výši 25 %. Když cut off hranici posuneme na percentil 40 %, tj. 0,111, pak dosáhne error I hodnoty 30,3 % a error II hodnoty 35,6 %.

Výsledný model dosahuje dobrých výsledků, zároveň však obsahuje relativně méně vysvětlujících proměnných oproti modelům jiných autorů, důvodem může být restriktivní výběr proměnných, rozšíříme proto model o další proměnnou s cílem dosáhnout maximálního výsledku.

Postupujeme extenzivně a rozšíříme model o další proměnnou F2:

- Podíl vlastního kapitálu včetně závazků ve skupině


(VK – pohledávky za upsaný kapitál – dlouhodobá nehmotná aktiva – oceňovací rozdíly – odložené daně + dlouhodobé a krátkodobé závazky vůči spřízněným osobám) / (upravený vlastní kapitál + cizí capital)

Po přidání tohoto parametru získáme novou výslednou funkci:

$$\ln \frac{\pi}{1-\pi} = -2,504 - 0,517 L3 - 0,301 L9 - 0,268 F6 - 0,257 D8 - 0,178 F2 \quad (9)$$

Obrázek 3 Přehled křivky CAP, AR 48,2%

Figure 3 Cumulative Accuracy Profile, AR 48,2%



Zdroj: vlastní výzkum

Source: own research

Notes: ¹Fraction of all companies, ²Fraction of defaulted companies.

Tabulka 8 Transformace dat

Table 8 Transformation parameters

	Dolní hranice ¹	Horní hranice ²	Medián ³	Směrodatná odchylka ⁴	Změna znaménka ⁵
F2	-0,05	0,3	0,3	0,109	Ne ⁶

Zdroj: vlastní výzkum

Source: own research

Notes: ¹Low cut-off, ²Hi cut-off, ³Median, ⁴Standard deviation, ⁵Reverse, ⁶No.

Wald test nezamítá na 5% hladině spolehlivosti hypotézu, že koeficient predikátoru F2 je nula. Negativně v modelu působí silná korelace mezi F2 a F6 ve výši 55 %. Statistika -2LL (-2 log likelihood) vyšla statisticky významná s hodnotou 740. Test Hosmer-Lemeshow dosáhl hladiny významnosti = 0,46. Lze se tedy domnívat, že přidání tohoto parametru je ze statistického pohledu ještě na hraně akceptovatelnosti. Dle konfidenčních intervalů je vysoká šance, že koeficient je nenulový.

Tabulka 9 Wald test

Table 9 Wald test


	Odhad ²	Wald. - Stat.	Dolní LS - 95, % ³	Horní LS - 95, % ⁴	p
Abs.člen ¹	2,50368	318,7862	2,228846	2,778523	0,000000
L3	0,51657	23,7592	0,308860	0,724288	0,000001
L9	0,30123	9,7491	0,112141	0,490312	0,001794
F6	0,26830	7,9152	0,081386	0,455205	0,004902
D8	0,25662	5,8634	0,048907	0,464338	0,015459
F2	0,17792	2,9038	-0,026721	0,382567	0,088373

Zdroj: vlastní výzkum

Source: own research

Notes: ¹ Absolute member, ² Estimate, ³ Low cut-off, ⁴ Hi cut-off.**Obrázek 4** Přehled křivky CAP, AR 49 %

Figure 4 Cumulative Accuracy Profile, AR 49 %



Zdroj: vlastní výzkum

Source: own research

Notes: ¹ Fraction of all companies, ² Fraction of defaulted companies.

Hodnota AR dosáhla 49 % (plocha pod ROC, kterou označujeme AUC dosáhla 75 %). Accuracy ratio na out of sample vzorku dosáhlo 48,6 % (AUC 74 %). Tento model dosáhl téměř totožného výsledku na záložním vzorku. Při stanovení cut off skóre na úrovni percentilu 30 %, tj. 0,141, vychází error I ve výši 36,6 % a error II ve výši 24,9 %. Při cut off hranici na percentilu 40 %, tj. 0,11 pak dosáhl error I hodnoty 26,1 % a error II hodnoty 35 %.

Statistická analýza ukazuje, že existuje srovnatelný ukazatel jako D8, který dosahuje stejných či mírně lepších výsledků. Postupujeme nahrazením ukazatele krytí úroků ukazatelem krytí dluhů z běžného cash flow.

Nahrazení proměnné D8 za D2:

- Krytí dluhů běžným cash flow (běžné cash flow / (bankovní úvěry a půjčky + vydané dluhopisy + závazky z leasingu).

Po přidání tohoto parametru získáme novou výslednou funkci:

$$\ln \frac{\pi}{1-\pi} = -2,543 - 0,537 L3 - 0,310 L9 - 0,226 F6 - 0,214 D2 - 0,196 F2 \quad (10)$$

Tabulka 10 Transformace dat

Table 10 Transformation parameters

	Dolní hranice ¹	Horní hranice ²	Medián ³	Směrodatná odchylka ⁴	Změna znaménka ⁵
D2	-0,25	0,5	0,33	0,22	Ne ⁶

Zdroj: vlastní výzkum

Source: own research

Notes: ¹Low cut-off, ²Hi cut-off, ³Median, ⁴Standard deviation, ⁵Reverse, ⁶No.

Wald test u koeficientu proměnné F2 vyšel v tomto případě výrazně lépe oproti předchozímu modelu a blíží se pětiprocentní hranici spolehlivosti. Korelace v modelu mezi F6 a D2 dosahuje 41 %. Statistika -2LL (-2 log likelihood) vyšla statisticky významná s hodnotou 741. Test Hosmer-Lemeshow dosáhl hladiny významnosti = 0,43. Hodnota AR dosáhla 49,7 % (plocha pod ROC, kterou označujeme AUC dosáhla 75 %). Accuracy ratio na out of sample vzorku dosáhlo 47,5 % (AUC 74 %). Statistiky modelu vyšly celkově lépe oproti předchozímu modelu, mírně hůře dopadl při testech na záložním vzorku. Na obrázku 5 je zobrazen průběh křivky CAP, která dosahuje mírně vyšší Accuracy ratio oproti křivce předešlého modelu, opticky je možno vidět, že je více zalomená na 40% procentním kvantilu.

Tabulka 11 Wald test

Table 11 Wald test


	Odhad ²	Wald. - Stat.	Dolní LS - 95, % ³	Horní LS - 95, % ⁴	p
Abs. člen ¹	2,543412	329,2033	2,268665	2,818159	0,000000
L3	0,536518	25,9131	0,329945	0,743091	0,000000
L9	0,310161	10,4217	0,121855	0,498467	0,001245
F6	0,225873	5,0190	0,028266	0,423480	0,025070
D2	0,213961	4,9566	0,025601	0,402322	0,025991
F2	0,195720	3,5065	-0,009135	0,400575	0,061129

Zdroj: vlastní výzkum

Source: own research

Notes: ¹Absolute member, ²Estimate, ³Low cut-off, ⁴Hi cut-off.**Obrázek 5** Přehled křivky CAP, AR 49,7%

Figure 5 Cumulative Accuracy Profile, AR 49,7%



Zdroj: vlastní výzkum

Source: own research

Notes: ¹Fraction of all companies, ²Fraction of defaulted companies.

Při stanovení cut off skóre na úrovni percentilu 30 %, tj. 0,142, vychází error I ve výši 37,3 % a error II ve výši 25 %. Při cut off hranici na percentilu 40 %, tj. 0,109, pak dosáhl error I hodnoty 23,9 % a error II hodnoty 34,7 %. Tento výsledek je nejlepší ze všech zde odvozených modelů.

5 Diskuse

Postupně byly prozkoumány modely o třech, čtyřech a pěti proměnných, kdy nejlepšího výsledku prediktivní schopnosti dosahuje poslední zkoumaný model.

Tento model vykazuje relativně uspokojivé výsledky z pohledu rozlišování mezi defaultními a nedefaultními firmami, vezmeme-li v úvahu, že se jedná o model odvozený pouze na základě finančních ukazatelů a je odvozen na základě výkazů malých a středních firem. Zároveň model vykazuje statistickou stabilitu a dosáhl stabilní sílu na záložním vzorku (out of sample).

Z pohledu nejvíce vysvětlujících proměnných byly jako nejvýznamnější potvrzeny ukazatele likvidity, zadluženosti, resp. podílu vlastního kapitálu a dluhové kapacity. Poslední zkoumaný model nahrazuje ukazatel krytí úroků běžným cash flow ukazatelem krytí dluhů běžným cash flow. Tento ukazatel se jeví vhodnější zejména u společností se splátkovými úvěry, u kterých je důležitější krytí dluhů oproti krytí pouze úroků, dalším důvodem může být, že firma procházející nepříznivým obdobím může být vystavena tlaku svých věřitelů na snižování svých dluhů a je pro ni tak důležitá přiměřenost dluhů k tvorbě zdrojů. Celková výsledná funkce se jeví jako logická a je v souladu s předpokladem, že závazky jsou hrazeny peněžními prostředky.

Model nezahrnuje žádný klasický samostatný ukazatel rentability. Rozšíření modelu o rentabilitu tržeb, rentabilitu aktiv, rentabilitu vlastního kapitálu nebo marži přidané hodnoty nevedlo ke zvýšení prediktivní schopnosti modelu. Naopak rentabilita tržeb a rentabilita aktiv se v modelu chová nelogicky a nebylo je možno použít. Výsledek můžeme interpretovat tak, že se jedná o účetní pohled na zisk, který nemá tak silný vztah k defaultu společnosti v krátkém období.

Závazky společnost musí hradit z peněz a ty bezprostředně souvisí zejména s likviditou a peněžním tokem. Svou roli má výše dluhů a vlastního kapitálu. V modelu je obsažen ukazatel doby obratu pohledávek, což je také ukazatel, který úzce souvisí s peněžním tokem, finanční tíseň u malých a středních podniků je zřejmě často spojena se špatnou platební morálkou odběratelů. Úzkou spojitost s defaultem prokazuje ukazatel doby placení závazků, jeho silná korelace s ukazatelem doby obratu pohledávek a rychlé likvidity však eliminují jeho přínos v modelu. Místo rentability je v modelu zahrnut ukazatel úrokového krytí, resp. krytí dluhů, ve kterém figuruje běžný peněžní tok, což je vlastně upravený zisk o nepeněžní účetní položky a neprovozní vlivy (běžný HV po zdanění + odpisy + nepeněžní náklady (změny OP, rezerv) – nepeněžní výnosy (změny OP, rezerv) – zisk/+ztráta z prodeje dlouhodobého majetku – zisk/+ztráta z prodeje cenných papírů a podílů).

Výsledek analýzy potvrdil, že finanční ukazatele obsahují informace k tvorbě modelu predikce finanční tísně malých a středních podniků, zároveň však existuje významná část podniků, u kterých není model finanční problémy rozpoznat, nutno však podotknout, že toto souvisí i s definicí defaultu a horizontem, na který je prováděna predikce.

Zajímavé je porovnávat výsledek s modely, které prezentuje Altman a Sabato (2006), kdy jejich model u SME firem na základě finančních ukazatelů dosáhl AR 75,4% oproti výše dosaženému modelu 49,7 %. Metodika Altman a Sabato (2006) však byla rozdílná, zejména v oblasti definování okamžiku defaultu a velikosti firem, u jejich modelu je default definován až úpadkem (bankrotem) společnosti dle právního řádu a jednalo se o firmy s obratem až do výše 65 mil. USD.

Srovnatelné výsledky prediktivní schopnosti modelu odvozeného na základě finančních ukazatelů odvozených z účetnictví uvádí práce Altman, Sabato a Wilson (2010), kde model dosáhl AUC ve výši 67 % a 71 %. Zde odvozený model dosáhl vyšší AUC a to 75%. Výzkumy dále dokazují, že významným faktorem pro predikci finanční tísně u malých a středních firem jsou také nefinanční ukazatele, tzv. kvalitativní ukazatele, které např. u Altman, Sabato, Wilson vedly ke zpřesnění modelu až o 13 % na AUC 76 %.

6 Závěr

Podařilo se kvantifikovat schopnosti finančních ukazatelů jako predikátorů finanční tísně. Při tvorbě regresní funkce je možno kombinovat různé varianty finančních ukazatelů, avšak jejich vysoká vzájemná korelace v rámci skupiny vede k tomu, že v modelu kombinujeme ukazatele rentability, likvidity, aktivity, zadlužení a dluhové kapacity. Nejvýznamnějšími finančními ukazateli u SME v ČR k předpovědi finanční tísně v krátkém horizontu byly na zkoumaném vzorku identifikovány výše zadlužení a likvidita. Lepších výsledků dosahují ukazatele rentability a dluhové kapacity odvozené od běžného cash flow, které je zde počítáno nepřímou metodou úpravou zisku.

Literatura

- Altman, E. I., 1968. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, roč. 1968, č. 4, s. 589-609. ISSN 0022-1082.
- Altman, E. I. a G. Sabato, 2006. Modeling Credit Risk for SMEs: Evidence from US Market. *Working Paper*, Stern School of Business, roč. 2006, 1-43. ISSN 1547-3651
- Altman, E. I. a G. Sabato, N. Wilson, 2010. The Value of Non-financial Information in Small and Medium-sized Enterprise Risk Management. *The Journal of Credit Risk*, 2010 (2), 95-127. ISSN 1744 6619.
- Aquino, S., 2010. Accounting Indicators for Credit Risk Analysis of Firms: a Historical Perspective. *Economia Aziendale Online*, 1(2), 145-154. ISSN 2038-5498.
- Beaver, W. H., 1966. Financial ratios as predictors of failure, Empirical Research in Accounting: Selected Studies. *Journal of Accounting Research*, 4 (special issue), 71-111, ISSN 0021-8456.
- Engelmann, B., E. Hayden a D. Tasche. 2003. Measuring the Discriminative Power of Rating Systems. *Deutsche Bundesbank, Discussion paper, Series 2: Banking and Financial Supervision*, (1), 1-24. ISBN 3-935821-67-0.
- Gurčík, L., 2002. G-index – metoda predikce finančního stavu poľnohospodárskych podnikov. *Agri. Econ.*, 48(8), 373-378. ISSN 0139-570X.
- Kopta, D., 2006. Metody predikce finanční tísně u zemědělských podniků. In: *International scientific days 2006, Competitiveness in the EU – Challenge for the V4 countries*, Nitra: Slovenská poľnohospodárska univerzita v Nitre, s. 1065-1073. ISBN 80-8069-704-3.
- Neumaier, I. a I. Neumaierová. 2005. Index IN 05. In: *Evropské finanční systémy*, Brno: Ekonomicko-správní fakulta Masarykovy university v Brně, s. 143-148. ISBN 80-210-3753-9.
- Oesterreichische Nationalbank, 2004. Guidelines on Credit Risk Management, Rating Models and Validation. *Working papers*. Dostupné z: www.oenb.at/en/img/rating_models_tcm16-22933.pdf.
- Ohlson, J. A., 1980. Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*, roč. 18(1), 109-131. ISSN 0021-8456.
- Sobehart, J. a S. Keenan, R. Stein, 2000. Rating Methodology-Benchmarking Quantative Default Risk Models: A Validation Methodology. *Moody's Investor Service*. 2000.
- Witzany, J. *Credit Risk Management and Modeling*. 1. vyd., Praha: Nakladatelství Oeconomica, 2010, ISBN 978-80-245-1682-0.

Financial Ratios as Financial Distress Predictors for SME in Czech Republic

Jan Adamec

Abstract: *Constructing models for predicting financial distress of small and medium enterprises requires its own treatment, because these firms differ from large companies. The aim of this paper is to quantify the predictive power of selected ratios and to develop a statistical model for financial distress. We tested 16 financial ratios and the study relies on observations from 1563 firms. The model obtained by a methodology of conditional logit analysis includes quick liquidity ratio, average receivables collection period, leverage, solvency and interest coverage or debt coverage from current cash flow. The result confirmed that financial distress is closely related with the ability of a firm to pay its debts. Rentability wasn't found as so decide predictor in short period, there is a more complicated relation between rentability and payment capacity. As significant predictor was identified current cash flow (adjusted ordinary profit), which is much closely connected with cash.*

Key words: SME Finance · Modeling Credit Risk · Accounting Ratio Analysis · Predictors of Failure

JEL Classification: G32 · G33 · C35