

SKÓRING JAKO INDIKÁTOR FINANČNÍ STABILITY

Petr Jakubík, ČNB a Petr Teplý, IES FSV UK

Článek představuje model finančního skóringu odhadnutý na účetních datech českých podniků. Je identifikováno sedm finančních ukazatelů, které jsou schopny vysvětlit úpadek podniků na jednoročním predikčním horizontu. Na základě takto odhadnutého modelu je následně konstruován agregátní ukazatel bonity českého podnikového sektoru a ukázán jeho vývoj v čase. Tento indikátor přispívá k odhadu vývoje rizik tohoto sektoru a rozšiřuje stávající analytický aparát používaný Českou národní bankou v rámci analýz finanční stability. Výsledky článku ukazují, že se bonita českého podnikového sektoru mezi roky 2004 až 2006 postupně zlepšovala.

1. ÚVOD

Metody kreditního skóringu jsou standardní součástí řízení rizik finančních institucí. Jedná se o postupy umožňující věřitelům na základě odhadu pravděpodobnosti defaultu¹¹⁸ ohodnotit bonitu svých potenciálních dlužníků s cílem získání kvalitního úvěrového portfolia. Mezi nejčastěji využívaný typ kreditního skóringu v bankách pro segment právnických osob patří finanční skóring. V tomto případě jsou firmy posuzovány na základě finančních charakteristik vycházejících z jejich účetních závěrek. Výsledkem finančního skóringu je skóre firmy vyjadřující její bonitu. Analogicky je možno tento typ modelu aplikovat na data agregátní ekonomiky a konstruovat indikátor finanční stability vycházející z bonity nefinančního sektoru. Z pohledu ohodnocení kreditních rizik může být ukazatel dále použit jako doplněk sektorálních makroekonomických modelů, které byly odhadnuty pro českou ekonomiku a začleněny do zátěžových testů bankovního sektoru (Jakubík 2007a).

Článek se nejprve stručně věnuje definici skóringových modelů a jejich odhadu (část 2). V části 3 jsou diskutovány finanční ukazatele podniků, které mohou být využity jako vysvětlující proměnné pro úpadek firmy. Část 4 obsahuje popis použitých dat pro odhad modelu. Výsledný odhadnutý model je prezentován v části 5 a v části 6 je následně ukázána jeho aplikace na agregátních datech celého sektoru a odhad indikátoru bonity sektoru nefinančních podniků. V poslední části jsou shrnuty dosažené výsledky.

2. SKÓRINGOVÁ FUNKCE

Úkolem skóringových modelů je rozhodnutí, zda úvěrový obchod poskytnout.¹¹⁹ K tomu v praxi dochází na základě srovnání dostupných informací o klientovi (získaných například z formuláře žádosti o úvěr nebo záznamu o klientském chování v minulosti) s informacemi o minulých klientech, kterým byl obchod poskytnut v minulosti a jejichž kvalita je známa. Z historických informací o klientech je odhadnut predikční skóringový model. Aplikací modelu na známé informace o potenciálním dlužníkovi je získána pravděpodobnost, že u něj dojde ke kreditní (úvěrové) ztrátě. Rozhodnutí je učiněno porovnáním odhadnuté pravděpodobnosti ztráty s určitou prahovou hodnotou. Přehled těchto metod v kontextu kreditního skóringu lze najít například v (Hand, Henley 1997) a (Rosenberg, Gleit 1994).

Při konstrukci skóringových funkcí je možno využít celou řadu statistických metod jako například lineární regresi, rozhodovací stromy, neuronové sítě nebo expertní systémy. V praxi je však nejčastěji používanou metodou logistická regrese. V tomto případě se předpokládá, že vysvětlující proměnné násobené příslušnými koeficienty mají lineární vztah k přirozenému logaritmu četnosti případů defaultu (označovanému jako logitu, (Mays 2001).

¹¹⁸ Default je obecně definován jako nedodržení závazku dlužníka vyplývajícího z úvěrové smlouvy. Basel Committee on Banking Supervision (2006) definuje default dlužníka jako situaci, kdy nastane alespoň jedna z následujících událostí. První možností je situace, kdy banka zjistí, že je nepravděpodobné, že by dlužník splatil svůj úvěrový závazek v plné výši bez dodatečné akce ze strany banky jako realizace zástavy. Druhou možností je situace, při které má dlužník některý ze svých závazků více než 90 dní po splatnosti. V tomto článku budeme defaultem rozumět úpadek firmy.

¹¹⁹ Predikci defaultu podniků na základě finančních ukazatelů se zabývali již v 60 letech Altman (1968) a Beaver (1966). K rozvoji těchto metod dále došlo v 80. a zejména v 90 letech například Dimitras, Slowinski, Susmaga, Zopounidis (1999). V české literatuře se kreditnímu skóringu věnuje například Jakubík (2003).

$$\ln \frac{s}{1-s} = b_0 + \sum_{i=1}^N b_i x_i, \quad (1)$$

kde

s - odpovídá pravděpodobnosti úpadku firmy v jednoročním predikčním horizontu,

x_i - označuje finanční ukazatele firmy,

b_i - označuje koeficienty příslušných ukazatelů skóringové funkce.

Z této rovnice pak lze odvodit vztah pro pravděpodobnost defaultu. Tento vztah lze popsat logistickou křivkou.

$$s = \frac{1}{1 + e^{-b_0 - \sum_{i=1}^N b_i x_i}} \quad (2)$$

Jako vysvětlující proměnné jsou v případě finančního skóringu uvažovány finanční ukazatele založené na účetních datech. Koeficienty funkce lze odhadnout pomocí metody maximální věrohodnosti (Baltagi 2002). Vzhledem k velkému množství indikátorů, které mohou být zařazeny do modelu, se k výběru proměnných používá postupná (stepwise) regrese. Tato metoda spočívá v testování různých kombinací proměnných maximalizujících kvalitu modelu. Model pracuje s binární závislou proměnnou (0/1) a může být konstruován jak pro výpočet pravděpodobnosti defaultu, tak pravděpodobnosti, že nedojde k defaultu v závislosti na definici závislé proměnné v regresi. Pokud označíme tzv. špatnou firmu¹²⁰ hodnotou 1, pak výsledné číslo získané z modelu koresponduje s pravděpodobností, že u firmy dojde k úpadku.¹²¹

Pokud předpokládáme velké množství firem použitých k odhadu modelu (1), pak podle zákona velkých čísel odpovídá proměnná s v rovnicích (1) a (2) podíl firem, u kterých dochází na jednoročním predikčním horizontu k jejich úpadku. Za předpokladu, že by byl model (2) odhadnut na množině firem, na které bude poté funkce aplikována, představuje výsledek modelu skutečně pravděpodobnost defaultu. Vzhledem k tomu, že zastoupení dobrých a špatných firem ve vzorku obvykle neodpovídá reálnému stavu a současně jsou do úvahy brány účetní data z různých časových okamžiků, není možno výsledek modelu interpretovat jako pravděpodobnost defaultu. V této souvislosti se o proměnné s mluví zpravidla jako o skóre vyjadřujícím riziko či bonitu firmy.¹²²

3. FINANČNÍ UKAZATELE

Finanční ukazatele, sloužící jako vysvětlující proměnné v modelu (2), lze dělit podle několika hledisek – například pohledu věřitelů, akcionářů, státních orgánů. Je třeba zdůraznit, že v teorii ani v praxi neexistuje jednoznačná shoda na ideální metodě analýzy finančních ukazatelů. V české literatuře různí autoři prezentují různá členění poměrových ukazatelů – viz například (Blaha, Jindřichovská 2006) a (Kislingerová 2007). Podobná nejednotnost panuje i v zahraniční literatuře – viz například (Damodaran 2002) a (McKinsey & Co. 2005).

S ohledem na primární cíl našeho výzkumu, kterým je konstrukce indikátoru finanční stability na základě predikce úpadku společnosti, jsme vybrali 22 ukazatelů a rozdělili je do čtyř hlavních skupin: ukazatele likvidity, ukazatele zadluženosti, ukazatele ziskovosti a ukazatele aktivity. Jednotlivé finanční ukazatele jsou uvedeny v tabulce 1. U každého ukazatele je rovněž vyznačen jeho teoretický vliv na úpadek firmy (kladný nebo záporný).

Ukazatele likvidity zkoumají schopnost firmy splácet krátkodobé závazky (ukazatele r1, r2, r15 a r19) případně schopnost krýt dlouhodobé závazky dlouhodobým majetkem (ukazatel r10). Obecně platí, že vyšší likvidita impli-

¹²⁰ Špatná firma zde bude definována jako firma, u které došlo k úpadku během sledovaného období, přičemž v období před úpadkem byla dobrá. Dobrou firmou budeme rozumět firmu, u které nedošlo ve sledovaném období k úpadku.

¹²¹ Některé studie označují naopak číslem 1 tzv. dobré firmy. V tomto případě výsledné skóre představuje pravděpodobnost, že u firmy nedojde k defaultu.

¹²² Získané číslo je možno pomocí vhodné transformace převést na pravděpodobnost defaultu. K tomuto účelu je možno využít jak parametrické tak neparametrické odhady.

kuje nižší pravděpodobnost úpadku společnosti. Přetrvávající problémy s nízkou likviditou společnosti obvykle předznamenávají blížící se problémy se splácením dlouhodobých závazků společnosti (tj. pokles solventnosti společnosti¹²³), což může v extrémním případě skončit jejím úpadkem.

Ukazatele zadluženosti popisují schopnost firmy splácet dlouhodobé závazky. Obecně platí, že vyšší zadluženost (ukazatele r3, r4, r14) a také delší doba splácení dluhů (ukazatel r9) má za následek vyšší pravděpodobnost defaultu společnosti. Naopak schopnost společnosti generovat dostatek prostředků pro splácení dluhů (ukazatele r5, r6, r13 a r16) a vyšší podíl vlastních zdrojů společnosti (ukazatel r17) tuto pravděpodobnost snižují.

Ukazatele ziskovosti vysvětlují, jakým způsobem společnost generuje zisk a kolik na to využívá vstupů. Obecně platí, že vyšší ziskovost implikuje nižší pravděpodobnost úpadku společnosti (ukazatele r7, r8, r20, r21).

Ukazatele aktivity měří efektivnost využívání různých vstupů společnosti. Z finančního pohledu by bylo ideální, kdyby společnost generovala tržby, resp. zisk za pomoci minimálního množství zdrojů. Obecně se dá říci, že čím nižší je efektivnost společnosti, tím se dá očekávat vyšší pravděpodobnost jejího úpadku (ukazatele r11, r12 a r22). Ukazatel *doba obratu tržeb* (r18) je konstruován tak, že s růstem objemu tržeb roste hodnota ukazatele a pravděpodobnost úpadku klesá.

Potenciální vliv jednotlivých ukazatelů na bankrot společnosti lze ukázat na následujícím zjednodušeném příkladu.¹²⁴ Klasickým symptomem poklesu solventnosti společnosti může být skutečnost, že společnost neefektivně využívá vstupy (ukazatele aktivity se zhoršují), snižuje se tudíž příjem hotovostních toků do firmy, což má za následek pokles schopnosti firmy splácet krátkodobé závazky (ukazatele likvidity se zhoršují). Postupem času se ukáže, že společnost není schopna generovat zisk (ukazatele ziskovosti se zhoršují) pro pokrytí krátkodobých a dlouhodobých závazků (ukazatele zadluženosti se zhoršují), závazky firmy převyšují její aktiva a dochází k bankrotu firmy.

Pro odhad modelu (1) byly finanční ukazatele získané na základě vztahů uvedených v tabulce 1 dále transformovány na jejich relativní pořadí vůči použitému datovému vzorku. Tím byla každá hodnota ukazatele převedena na číslo z intervalu 0 až 1. Touto jednoduchou transformací zajistíme větší robustnost odhadu modelu vůči odlehilým hodnotám uvažovaných ukazatelů.

Tab. 1 – Finanční ukazatele

Název	Definice	Označení	Oček. dopad
Ukazatele likvidity			
Celková likvidita	$\frac{\text{oběžná aktiva}}{\text{oběžná pasiva}}$	r1	-
Běžná likvidita	$\frac{\text{finanční majetek} + \text{KDP}^i}{\text{oběžná pasiva}}$	r2	-
Okamžitá likvidita	$\frac{\text{finanční majetek}}{\text{oběžná pasiva}}$	r19	-
Pracovní kapitál	$\frac{\text{oběžná aktiva} - \text{oběžná pasiva}}{\text{aktiva}}$	r15	-
Kapitalizační míra	$\frac{\text{dlouhodobý majetek}}{\text{dlouhodobé závazky}}$	r10	-
Ukazatele zadluženosti			
Finanční páka I	$\frac{\text{cizí zdroje} + \text{ostatní pasiva}}{\text{vlastní kapitál}}$	r3	+
Finanční páka II	$\frac{\text{dlouhodobé úvěry} + \text{dlouhodobé dluhopisy}}{\text{vlastní kapitál}}$	r4	+
Finanční páka III	$\frac{\text{cizí zdroje}}{\text{aktiva}}$	r14	+

¹²³ Likvidita se někdy označuje jako krátkodobá solventnost společnosti.

¹²⁴ V tomto zjednodušeném příkladu neuvažujeme alternativní způsoby na ozdravení firmy (např. restrukturalizace firmy, kapitalizace dluhů apod.).

Tab. 1 – Finanční ukazatele - pokračování

Název	Definice	Označení	Oček. dopad
Ukazatele zadluženosti			
Doba splatnosti dluhů	$\frac{DDZ^{ii} + KDZ^{iii}}{\text{provozní zisk} + \text{odpisy}}$	r9	+
Úrokové krytí	$\frac{\text{provozní zisk}}{\text{nákladové úroky}}$	r5	-
Peněžní tok I	$\frac{\text{čistý zisk} + \text{odpisy}}{(\text{cizí zdroje} - \text{rezervy})/365}$	r6	-
Peněžní tok II	$\frac{\text{čistý zisk} + \text{odpisy}}{\text{cizí zdroje}/365}$	r13	-
Nulový úvěrový interval	$\frac{(\text{peníze} + \text{KDPI} - \text{KDZ}^{iii})}{\text{provozní náklady}}$	r16	-
Zadržovaný zisk	$\frac{\text{zadržovaný zisk}}{\text{aktiva}}$	r17	-
Ukazatele ziskovosti			
Hrubá zisková marže	$\frac{\text{provozní zisk}}{\text{tržby}}$	r7	-
Výnosnost aktiv	$\frac{\text{provozní zisk}}{\text{aktiva}}$	r8	-
Výnosnost kapitálu	$\frac{\text{čistý zisk}}{\text{kapitál}}$	r20	-
Čistá zisková marže	$\frac{\text{čistý zisk}}{\text{tržby}}$	r21	-
Ukazatele aktivity			
Doba inkasa pohledávek	$\frac{\text{pohledávky}}{\text{tržby}/365}$	r11	+
Doba obratu zásob	$\frac{\text{zásoby}}{\text{tržby}/365}$	r12	+
Doba obratu tržeb	$\frac{\text{tržby}}{\text{aktiva}}$	r18	-
Doba obratu závazků	$\frac{\text{krátkodobé závazky}}{\text{tržby}/365}$	r22	+

ⁱ Krátkodobé pohledávkyⁱⁱ Dlouhodobé závazkyⁱⁱⁱ Krátkodobé závazky

4. POUŽITÁ DATA

Pro náš výzkum jsme použili obsáhlou databázi společnosti Česká kapitálová informační agentura (ČEKIA), která obsahuje účetní závěrky (rozvahy a výsledovky) vybraných českých firem za období 1993 až 2005. Z celkového počtu 31 612 firem v databázi došlo ke konkurzu u 932 společností. Vzhledem k tomu, že některé účetní závěrky byly velmi řídky vyplněny, zaměřili jsme se na záznamy firem s vyplněným hlavním odvětvím ekonomické činnosti (OKEČ), které měly většinu účetních položek vyplněnu. Pro účely odhadu skóringové funkce jsme nejprve z firem, u nichž došlo ke konkurzu, vybrali pouze ty s účetními daty jeden rok před prohlášeným konkurzem. Takových firem bylo 151.¹²⁵ Dále jsme pro vzorek firem, u kterých nedošlo ve sledovaném období k úpadku, vybrali pouze ty, pro které byly k dispozici účetní závěrky minimálně pro dva po sobě následující roky.¹²⁶ Datový vzorek pro odhad

¹²⁵ Z našich analýz jsme zcela vyloučili firmy, u kterých došlo k vyrovnání. V databázi bylo pouze devět takových případů. Oproti konkurzu není totiž vyrovnání spojeno se zánikem právnické osoby (Jakubík 2007b).

¹²⁶ K odhadu skóringové funkce je třeba mít k dispozici účetní data firem pro dva bezprostředně následující roky. První období je použito pro odhad funkce, druhé pro identifikaci kvality firmy (firma v úpadku, zdravá firma). Pokud nejsou pro danou firmu k dispozici účetní data následujícího období, jedná se o společnost, o jejíž kvalitě nejsme schopni rozhodnout.

modelu byl konstruován tak, aby co nejlépe postihoval reálnou strukturu dat. Obvykle se však do vzorku zahrne větší podíl špatných firem než odpovídá realitě, aby bylo možno pomocí statistických metod odlišit skupinu dobrých a špatných společností. Někdy se pracuje se vzorkem obsahujícím stejný počet dobrých a špatných firem (Wezel 2005). Obecně se vybírají dobré firmy tak, aby dle zvoleného kritéria byly co nejvíce podobné špatným, například z pohledu velikosti měřené aktivy, počtem zaměstnanců či tržbami.¹²⁷ Dále jsme náhodně zvolili účetní období, pro která byla k dispozici rovněž závěrka za účetní období bezprostředně následující. Tím jsme zabezpečili, že se skutečně jedná o firmu, u které v roce následujícím od doby sledování nedošlo k úpadku. Na základě popsaného postupu bylo nakonec vybráno 606 dobrých firem. Datový vzorek tak obsahoval celkem 757 firem, které byly rozděleny do dvou kategorií podle toho, zda zbankrotovaly v období následujícím po období, kdy byla vybrána účetní data pro danou společnost. Podle ekonometrické literatury logistická regrese při malém zastoupení sledované události podhodnocuje vliv charakteristik na tyto události, proto se vytváří umělý vzorek a odhadnuté hodnoty se dále transformují, aby případně odpovídaly výskytu v populaci.¹²⁸

Tabulka 2 ukazuje rozdělení dat v databázi na vybraném datovém vzorku podle účetního období a kvality firem („dobré/špatné“). V rámci celého datového vzorku navíc existuje skupina firem, u které nejsme schopni o kvalitě v daném roce rozhodnout („neurčitě firmy“). Jedná se o firmy, u nichž nejsou k dispozici účetní závěrky v následujícím roce. Ačkoli databáze obsahovala účetní data za období 1993-2005, v posledním roce již není možné o kvalitě firem rozhodnout. Z tohoto důvodu vybraný datový vzorek období 2005 neobsahuje.

Tab. 2 – Rozdělení datového vzorku podle účetního období a kvality firem*

	Celý datový zdroj				Použitý datový vzorek		
	Celkem	Neurčitě firmy	Špatné firmy	Dobré firmy	Celkem	Špatné firmy	Dobré firmy
1993	980	89	1	890	1	1	0
1994	1 824	53	0	1 771	4	0	4
1995	5 606	147	0	5 459	13	0	13
1996	7 023	1 032	9	5 982	53	9	44
1997	7 056	1 261	15	5 780	50	15	35
1998	6 802	1 028	12	5 762	48	11	37
1999	7 541	1 307	25	6 209	69	25	44
2000	7 377	3 094	18	4 265	62	17	45
2001	5 660	1 536	5	4 119	40	5	35
2002	7 869	956	8	6 905	57	8	49
2003	22 264	4 420	25	17 819	110	25	85
2004	18 989	18 490	35	464	250	35	215
Celkem**	98 991	33 413	153	65 425	757	151	606

Pramen: ČEKIA a vlastní výpočty

* Špatnou firmou rozumíme firmu, u které došlo k bankrotu v horizontu jednoho roku. Naopak dobrou firmou pro dané období je označována firma, u které nedošlo k bankrotu během následujícího roku.

** Řádek celkem obsahuje počet pozorování pro danou množinu firem. Na celém datovém vzorku toto číslo neodpovídá celkovému počtu firem, protože ve výběru je každá společnost sledována za několik účetních období.

Tabulka 3 ukazuje rozdělení firem podle velikosti v rámci datového vzorku, které je založeno na aktivech firem a které je v souladu s dělením podle Evropské komise.¹²⁹ Nicméně je třeba zmínit, že Evropská komise nabízí i další členění společností dle velikosti (například podle počtu zaměstnanců či výše tržeb).¹³⁰ Námí zvolená definice veli-

¹²⁷ Přehled metod lze nalézt např. v Heckman a kol. (1997).

¹²⁸ Pro odhad skóringové funkce byl v rámci testů robustnosti použit alternativně vzorek konstruovaný stejným způsobem, ale s novým náhodným výběrem pro dobré firmy viz část 5 pojednávající o výsledcích modelu.

¹²⁹ Nařízení Komise (ES) č. 70/2001 se změnou 364/2004 Sb. Hranice velikosti firmy byly přepočteny z EUR na Kč podle orientačního kurzu 1 EUR = 30 CZK.

¹³⁰ Členění dle počtu zaměstnanců používá i Český statistický úřad.

kosti firmy použítá v tabulce 3 vycházela z dostupných údajů, které byly součástí použitého datového zdroje. Ten obsahoval aktiva firem, nikoli počty jejich zaměstnanců. Údaj o tržbách byl součástí databáze, nicméně byl vyplněn pouze pro některé společnosti, proto ho nebylo možno využít. Na základě námi použité definice mají v datovém vzorku největší zastoupení mikro firmy s aktivy do 60 mil. Kč, naopak nejnižší zastoupení mají velké firmy s aktivy nad 1 290 mil. Kč. Velké firmy však pokrývají více než 80% agregovaných aktiv firem zastoupených ve vzorku.

Tab. 3 – Popis použitého datového vzorku

Typ firmy	Aktiva (mil. Kč)	Dobré firmy			Špatné firmy		
		Počet	Podíl dle počtu (%)	Podíl dle výše aktiv (%)	Počet	Podíl dle počtu (%)	Podíl dle výše aktiv (%)
Mikro firmy	< 60	292	48,2%	0,8%	70	46,4%	1,0%
Malé firmy	61-300	138	22,8%	3,5%	36	23,8%	5,4%
Střední firmy	301-1,290	90	14,9%	10,8%	24	15,9%	14,7%
Velké firmy	>1,291	86	14,2%	84,9%	21	13,9%	78,9%
Celkem	-	606	100,0%	100,0%	151	100,0%	100,0%

Pramen: ČEKIA a vlastní výpočty

5. VÝSLEDKY MODELU

Výsledný model (3) potvrdil vztah mezi hodnotami ukazatelů likvidity, zadlužení, ziskovosti, aktivity a úpadkem firmy. Nejlepší statistické vlastnosti vykázal model zahrnující sedm statisticky významných ukazatelů (z celkového počtu 22 uvažovaných ukazatelů). Jedná se o tři ukazatele zadluženosti (*finanční páka I a II, úrokové krytí*), dva ukazatele ziskovosti (*výnosnost kapitálu a hrubá zisková marže*), jeden ukazatel likvidity (*okamžitá likvidita*) a jeden ukazatel aktivity (*doba obratu zásob*). Výsledný model má následující tvar:

$$skóre = \frac{1}{1 + e^{-(b_0 + b_1 r_1^* + b_2 r_4^* + b_3 r_5^* + b_4 r_7^* + b_5 r_{12}^* + b_6 r_{19}^* + b_7 r_{20}^*)}} \quad (3)$$

kde

skóre - vyjadřuje riziko firmy, které je spojeno s pravděpodobností, že v horizontu jednoho roku dojde k bankrotu firmy,

r_i - označuje jednotlivé finanční ukazatele firmy,

b_i - odpovídá koeficientům příslušných ukazatelů skóringové funkce,

* - označuje operátor relativního pořadí v procentech, který vrací relativní pořadí hodnoty daného ukazatele pro danou firmu vůči celému datovému vzorku využitému pro odhad modelu.¹³¹

¹³¹ Operátor relativního pořadí vrací číslo z intervalu 0 až 1. Jedná se o analogii hledání kvantilu na daném datovém vzorku s rozdílem, že hodnota, pro kterou hledáme pozici v daném vzorku, není jeho součástí. V praxi spočítáme hodnotu daného finančního ukazatele jako je například *okamžitá likvidita* a hledáme dvě nejbližší hodnoty ukazatele v datovém vzorku, mezi nimiž se hledaná hodnota nachází. Z relativního pořadí těchto dvou hodnot vypočteme lineární interpolací relativní pořadí pro hledanou hodnotu. Pokud ukazatel *okamžitá likvidita* nabývá například hodnotu 0,2, pak je pro ni operátor relativního pořadí spočítán lineární interpolací relativního pořadí dvou nejbližších hodnot k číslu 0,2 nacházejících se v datovém vzorku použitým pro odhad modelu, tedy čísel 0,1996 a 0,2015, jejichž relativní pořadí jsou 0,5733 a 0,5746. Výslednou hodnotu relativního pořadí poté získáme pomocí následujícího vztahu:

$$0,5733 \cdot \frac{0,2015 - 0,2}{0,2015 - 0,1996} + 0,5746 \cdot \frac{0,2 - 0,1996}{0,2015 - 0,1996} = 0,5736, \text{ tedy } 0,2^* = 0,5736.$$

Znamená to, že v původním datovém vzorku, na kterém byl model odhadnut, je 57,36 % hodnot tohoto ukazatele menších než 0,2.

Vzhledem k tomu, že model je založen na relativním pořadí ukazatelů ve vzorku, odhadnuté koeficienty funkce vyjadřují jejich relativní důležitost. Čím větší má ukazatel koeficient (v absolutní hodnotě), tím je větší jeho váha ve skóringové funkci.¹³² Z tohoto pohledu se jako nejdůležitější jeví ukazatele *úrokové krytí*, *okamžitá likvidita* a *finanční páka I* (tabulka 4).

Odhadnutý skóringový model potvrdil očekávání týkající se dopadu jednotlivých ukazatelů na úpadek firmy. Je zřejmé, že vyšší zadluženost zvyšuje pravděpodobnost úpadku firmy (viz ukazatele *finanční páka I a II*), naopak vyšší schopnost firmy splácet dluhy (viz ukazatel *úrokové krytí*) tuto pravděpodobnost snižuje. Podobně i vyšší ziskovost firmy (viz ukazatele *hrubá zisková marže* a *výnosnost kapitálu*) a vyšší likvidita firmy (viz ukazatel *okamžitá likvidita*) zvyšují finanční stabilitu firmy, resp. snižují pravděpodobnost jejího úpadku. Naopak nižší efektivnost firmy (viz ukazatel *doba obratu zásob*) implikuje nižší finanční stabilitu firmy.

Tab. 4 – Odhadnutý skóringový model

Ukazatel	Druh	Označení ukazatele	Označení koef.	Koeficient	Směrodatná chyba	Významnost
Konstanta	-	-	b ₀	2,4192	0,9289	0,009207
Finanční páka I	Zadluženost	r3	b ₁	2,5779	0,3788	0,000000
Finanční páka II	Zadluženost	r4	b ₂	1,7863	0,5727	0,001813
Úrokové krytí	Zadluženost	r5	b ₃	-3,4902	1,0005	0,000486
Hrubá zisková marže	Ziskovost	r7	b ₄	-2,4172	0,4802	0,000000
Doba obratu zásob	Aktivita	r12	b ₅	1,7679	0,4033	0,000012
Okamžitá likvidita	Likvidita	r19	b ₆	-3,3062	0,4246	0,000000
Výnosnost kapitálu	Ziskovost	r20	b ₇	-2,2491	0,5621	0,000063

Pramen: Vlastní výpočty


Ačkoli model potvrdil některé očekávané výsledky, např. že nejdůležitější pro predikci bankrotu společnosti jsou ukazatele zadluženosti a likvidity, překvapivým výsledkem je důležitost zásob, která je obsažena ve zmíněném ukazateli *doba obratu zásob* (tj. kolik dní má podnik zboží na skladě ve formě zásob). Čím vyšší je tento ukazatel, tím déle leží zboží ve skladu podniku a klesá tedy prodejnost zásob.¹³³ Vysvětlením důležitosti ukazatele může být vysoký stav neprodejných zásob, který byl typický pro podniky směřující k bankrotu. Podpůrným tvrzením může být skutečnost, že ukazatel *celková likvidita*, který zahrnuje zásoby do oběžných aktiv, se ukázal jako nevýznamný. Naopak jako významný se jeví ukazatel *okamžitá likvidita*, který výši zásob do oběžných aktiv vůbec nezapočítává. Výše uvedené implikuje, že prodejnost zásob – kromě jiných ukazatelů – hraje důležitou roli při predikci bankrotu podniku.

Cílem skóringového modelu je správně oddělit dobré a špatné firmy. Tato vlastnost vyjadřuje kvalitu odhadnuté funkce. K jejímu měření je možno použít například Giniho koeficient. Hodnota tohoto koeficientu by měla být co nejbližší hodnotě 1, což by znamenalo stoprocentní schopnost rozčlenění firem dle jejich kvality prostřednictvím skóringové funkce. Graficky lze kvalitu modelu demonstrovat pomocí histogramu (Graf 1) či Lorenzovy křivky (Graf 2).

¹³² Operátor relativního pořadí aplikovaný na jednotlivé finanční ukazatele použité ve skóringové funkci zajišťuje robustnost modelu vůči extrémním hodnotám.


¹³³ Nicméně je třeba zmínit, že různá odvětví vykazují různé *doby obratu zásob*. Např. zatímco výroba lodí vykazuje vysokou hodnotu tohoto ukazatele, maloobchod naopak velmi nízkou.

Graf 1 – Histogram odhadnuté skóringové funkce



Pramen: Vlastní výpočty

Graf 2 – Lorenzova křivka odhadnuté skóringové funkce



Pramen: Vlastní výpočty

Graf 1 ukazuje rozdělení firem použitého datového vzorku podle skóre a podle skutečnosti, zda u nich došlo k bankrotu. Modré sloupce vyjadřují procentuální zastoupení dobrých, červené špatných firem pro jednotlivé intervaly skóre. Ideální by byla situace, kdyby všem zbankrotovaným firmám bylo přiřazeno skóre 1 a všem zdravým skóre 0. K tomu ale v praxi nedochází, neboť kompletní charakteristiky firmy nejsme schopni pozorovat a pracujeme tak s nedokonalými informacemi. Odsud plyne, že funkce nemůže stoprocentně separovat firmy dle jejich kvality. Vždy existuje určitá množina špatných firem, které jsou klasifikovány jako dobré a obráceně. Snahou je, aby těchto případů bylo co nejméně.

Graf 2 zobrazuje kumulativní distribuci skóre dobrých a špatných firem. V ideálním případě zaručujícím stoprocentní míru separace by tato křivka měla podobu pravého uhlu. Z Lorenzovy křivky lze spočítat tzv. Giniho koeficient jako poměr plochy mezi zelenou křivkou a úhlopříčnou černou úsečkou k celé ploše pod touto úhlopříčkou. Obecně přijímaná hodnota Giniho koeficientu pro tento typ modelu se pohybuje nad hranicí 60 % v závislosti na použitých datech a účelu skóringu (Mays 2001). Námí odhadnutý model s hodnotou Giniho koeficientu 80,41 % splňuje požadavek dostatečné míry separace firem na použitém datovém vzorku.

Odhad modelu pro alternativní datový vzorek, konstruovaný dle stejných pravidel jako použitý vzorek, potvrdil dostatečnou robustnost našeho odhadu. Dále byla robustnost modelu testována na dalším alternativním datovém vzorku, který byl složen z dobrých klientů vybíraných zcela náhodně a jejich zastoupení dle členění podle aktiv bylo odlišné oproti alternativnímu i původnímu datovému vzorku. V tomto případě sice došlo k mírné změně modelu (2 ukazatele ze 7 byly nahrazeny jinými¹³⁴), přesto při aplikaci modelu na agregátních datech nefinančních podniků (diskutováno v části 6) byly získány podobné výsledky (úroveň výsledného skóre byla jiná vzhledem k jinému poměru dobrých a špatných klientů ve vzorku, ale vývoj skóre v čase byl obdobný). Rovněž dosažená kvalita modelu měřena pomocí Giniho koeficientu byla téměř totožná.

6. VYUŽITÍ MODELU PRO ÚČELY FINANČNÍ STABILITY EKONOMIKY

Finanční skóring je standardně využíván pro ohodnocení bonity jednotlivých firem. Pokud máme k dispozici agregovaná data za celý nefinanční sektor, mohli bychom si tento sektor představit jako jednu velkou hypotetickou firmu s agregovanou rozvahou. Alternativně, vzhledem k používání pouze poměrových ukazatelů, je možné na agregátní ukazatele pohlížet jako na charakteristiky průměrné firmy sektoru. Za předpokladu určité homogenity

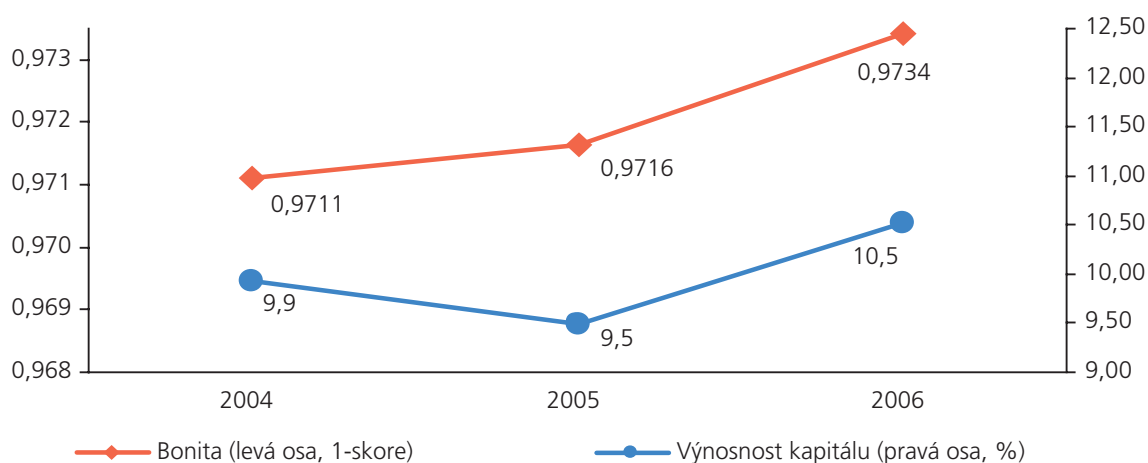
¹³⁴ Ukazatele zadrženy zisk a peněžní tok I byly nahrazeny ukazateli hrubá zisková marže a úrokové krytí.

Ize odhadnutý model aplikovat na agregátní ukazatele nefinančních podniků. Pokud se situace sektoru vyvíjí nepříznivě, dochází v průměru ke zhoršování finančních ukazatelů firem, což se odrazí v klesající hodnotě skóre průměrné reprezentativní firmy. Určitá omezení modelu však vyplývají z rozsahu a nehomogenního vzorku firem, na kterém byl odhadnut. Lepších výsledků bychom mohli dosáhnout rozčleněním vzorku na více homogennějších segmentů a následným odhadem modelu pro tyto skupiny firem odděleně. Ideálně bychom firmy rozčlenili dle velikosti a odvětví ekonomické činnosti. To však vzhledem k nízkému počtu špatných firem v použitém datovém zdroji není možné.

Agregovanou bilanci lze pro české firmy získat z veřejně dostupných dat Českého statistického úřadu, který má k dispozici data obsahující ekonomické výsledky nefinančních podniků. V dostatečně detailní struktuře, která umožňuje konstrukci sedmi výše uvedených ukazatelů zařazených do modelu, jsou zveřejňována tato data pouze pro podniky se 100 a více zaměstnanci. Takto získaných sedm ukazatelů ($r_3, r_4, r_5, r_7, r_{12}, r_{19}, r_{20}$) je dosaženo do rovnice (3), jejímž výsledkem je hodnota agregovaného skóre představující rizikovost celého sektoru.

Výsledné skóre bylo spočítáno pro roky 2004–2006.¹³⁵ Hodnoty ukazatele bonity (1- skóre) pro roky 2004–2006 (viz Graf 3) lze interpretovat jako bonitu nefinančního sektoru pro jednoroční predikční horizont. Tento ukazatel přímo souvisí s pravděpodobností úpadku podnikového sektoru. Ačkoli je na rozdíl od původního datového vzorku model aplikován na data firem se 100 a více zaměstnanci, je možno si vytvořit určitou představu o vývoji podnikového sektoru v čase. V souvislosti s uvedeným omezením je výsledné skóre zřejmě podhodnocené, a tedy bonita nadhodnocená vzhledem k vyšší rizikovosti malých firem nezahrnutých v agregátních datech. Pro účely finanční stability je však podstatná spíše než úroveň tohoto indikátoru jeho dynamika v čase. Výsledky naznačují postupné zlepšování bonity nefinančního sektoru mezi roky 2004 až 2006 v souladu s pozitivním makroekonomickým vývojem. I když v roce 2005 došlo k mírnému poklesu výnosu kapitálu a hrubé ziskové marže, pozitivní vývoj ostatních pěti ukazatelů (pokles zadluženosti, růst likvidity, zvýšení úrokového krytí, zkracování doby obratu zásob) převážil tento efekt a výsledná hodnota indikátoru bonity oproti roku 2004 mírně vzrostla. K pozitivnímu vývoji a omezení rizika sektoru dochází zejména v roce 2006. Ke zlepšení došlo u pěti ze sedmi sledovaných finančních ukazatelů (pouze u ukazatelů *finanční páka I a II* došlo ke zhoršení). Nejvyšší zlepšení vykázaly ukazatele *úrokové krytí* (meziroční zlepšení o 24,2 % na 11,78), *okamžitá likvidita* (meziroční růst o 24,2 % na 0,385) a *výnosnost kapitálu* (meziroční zlepšení o 10,7 % na 0,105). Výsledky modelu odpovídají závěrům obsaženým ve Zprávě o finanční stabilitě za rok 2006, podle které byl rok 2006 pro sektor velkých podniků mimořádně úspěšný a výhled na rok 2007 příznivý (ČNB 2007). Konstruovaný indikátor umožňuje komplexnější agregovaný pohled na budoucí vývoj rizikovosti sektoru jako celku.

Graf 3 – Vývoj bonity sektoru nefinančních podniků



Pramen: Vlastní výpočty a ČSÚ

¹³⁵ Vzhledem k tomu, že do roku 2004 nebyly sledovány některé položky z bilance nutné k výpočtu potřebných ukazatelů, byly tyto hodnoty pro rok 2004 odhadnuty z dostupných dat za roky 2004 a 2005.

7. ZÁVĚR

Finanční skóring je metoda sloužící k ohodnocování bonity dlužníků, a proto je často využívána věřiteli při rozhodování o poskytnutí úvěrových produktů. Tato studie ukázala možnost využití těchto tradičních metod i pro účely monitorování finanční stability podnikového sektoru. Na základě účetních dat českých firem byl pomocí logistické regrese odhadnut skóringový model založený na sedmi finančních ukazatelích. Aplikací tohoto modelu na agregátní výsledky hospodaření nefinančních podniků byla vypočtena hodnota skóre českého podnikového sektoru jako celku pro roky 2004–2006 odpovídající jeho rizikovosti pro jednoroční predikční horizont. Výsledky naší studie naznačují zlepšující se bonitu českého nefinančního podnikového sektoru mezi roky 2004 až 2006. Tento ukazatel bude začleněn do kvantitativního aparátu využívaného Českou národní bankou k vyhodnocování finanční stability. Každoročně bude vypočtená hodnota sloužit jako podpůrná informace k ohodnocení pravděpodobnosti problémů podnikového sektoru na jednoročním predikčním horizontu.

LITERATURA

- ALTMAN, E.I. (1968): *Financial ratios, discriminant analysis and the prediction of corporate bankruptcy*. The Journal of Finance XXIII 4, 589–609
- BALTAGI, B. D. (2002): *Econometrics*, Springer
- BASEL COMMITTEE ON BANKING SUPERVISION (2006): *International Convergence of Capital Measurement and Capital Standards: A Revised Comprehensive Framework*, Bank for International Settlements
- BEAVER, W. (1966), *Financial ratios as predictors of failure*. Journal of Accounting Research 4 (1966), 71–102
- BLAHA, Z. S., JINDŘICHOVSKÁ, I. (2006): *Jak posoudit finanční zdraví firmy: finanční analýza pro investory: bankéře, brokery, manažery, podnikatele i drobné akcionáře*, 3 vydání, Management Press
- ČNB (2007): *Zpráva o finanční stabilitě za rok 2006*
- DAMODARAN, A. (2002): *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset*. 2. vydání, John Wiley & Sons
- DIMITRAS, A. I., SLOWINSKI, R., SUSMAGA, R., ZOPOUNIDIS, C. (1999): *Business failure prediction using rough sets*. European Journal of Operational Research 17 3, 263–280
- HAND, D., HENLEY, W. (1997): *Statistical Classification Methods in Consumer Credit Scoring: A Review*. Journal of the Royal Statistical Society
- HECKMAN, J., ICHIMURA, H., TODD, P. (1997): *Matching as an Econometric Evaluation Estimator: Evidence from Evaluating a Job Training Program*, Review of Economic Studies, Vol. 64: 605–654
- JAKUBÍK, P. (2003): *Úloha skóringu při řízení kreditního rizika*. Acta Oeconomica Pragensia – Finanční krize, VŠE Praha, Vol. 1, 147–152
- JAKUBÍK, P. (2007a): *Macroeconomic Environment and Credit Risk*. Czech Journal of Economics and Finance, 57(1-2), 60–78
- JAKUBÍK, P. (2007b): *Exekuce, bankroty a jejich makroekonomické determinanty*. IES Working Papers 2007/29
- KISLINGEROVÁ E. (2007): *Manažerské finance*. 2. vydání, C.H. Beck
- MAYS E. (2001): *Handbook of Credit Scoring*. Glenlake Publishing Company, Ltd.
- MCKINSEY & CO. (2005): *Valuation – Measuring and Managing The Value of Companies*. 4. vydání, John Wiley & Sons
- ROSENBERG, E., GLEIT, A. (1994): *Valuation Quantitative methods in credit management: a survey*. Operations research 42, 580–612
- WEZEL, T. (2005): *Determinants of Foreign Direct Investment in Emerging Markets: An Empirical Study of FDI Flows from Germany and its Banking Sector*. Peter Lang GmbH, Frankfurt am Main