

Predikce bankrotu strojírenských podniků v EU

Vedoucí práce:

doc. Mgr. David Hampel, Ph.D.

Bc. Michaela Staňková

Zadání

Poděkování

Ráda bych touto cestou poděkovala svému vedoucímu doc. Mgr. Davidu Hampelovi, Ph.D. a také svému konzultantovi Ing. Václavu Klepáčovi, nejen za odborné vedení, cenné rady a připomínky, ale také za ochotu a vstřícný přístup během zpracování mé diplomové práce.

Čestné prohlášení

Prohlašuji, že jsem práci: **Predikce bankrotu strojírenských podniků v EU** vypracovala samostatně a veškeré použité prameny a informace uvádím v seznamu použité literatury. Souhlasím, aby moje práce byla zveřejněna v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a v souladu s platnou *Směrnicí o zveřejňování vysokoškolských závěrečných prací*.

Jsem si vědoma, že se na moji práci vztahuje zákon č. 121/2000 Sb., autorský zákon, a že Mendelova univerzita v Brně má právo na uzavření licenční smlouvy a užití této práce jako školního díla podle § 60 odst. 1 autorského zákona.

Dále se zavazuji, že před sepsáním licenční smlouvy o využití díla jinou osobou (subjektem) si vyžádám písemné stanovisko univerzity, že předmětná licenční smlouva není v rozporu s oprávněnými zájmy univerzity, a zavazuji se uhradit případný příspěvek na úhradu nákladů spojených se vznikem díla, a to až do jejich skutečné výše.

V Brně dne 21. května 2016

Abstract

Staňková, M. Prediction bankruptcy of engineering companies in the EU. Diploma thesis. Brno: Mendel University, 2016.

The diploma's thesis focuses on the problem of binary classification within the company bankruptcy prediction. The aim of the thesis is to apply selected methods on the financial data and consequently evaluate the accuracy of developed models for the predictability of bankruptcy. The theoretical part deals with the basic concept of financial analysis and also models which are used for the bankruptcy prediction nowadays. The practical part comes from the data of 953 engineering companies based in the EU. The data are elaborated by methods of multidimensional statistics, namely the classification using cluster analysis, decision trees and support vectors machines.

Keywords

Financial analysis, ratios, support vector machines, decision trees, cluster analysis, principal component analysis.

Abstrakt

Staňková, M. Predikce bankrotu strojírenských podniků v EU. Diplomová práce. Brno: Mendelova univerzita v Brně, 2016.

Diplomová práce se zabývá problémem binární klasifikace v rámci predikce bankrotu podniku. Cílem této práce je aplikovat vybrané metody na data finančního charakteru a následně vyhodnotit přesnost vypracovaných modelů pro predikci bankrotu. Teoretická část práce se zaměřuje na základní pojmy z oblasti finanční analýzy a dále pak na modely, které se pro predikci bankrotu dnes využívají. Praktická část vychází z dat 953 strojírenských společností z EU, které jsou zpracovány pomocí metod vícerozměrné statistiky, konkrétně se jedná o klasifikaci pomocí shlukové analýzy, rozhodovacích stromů a metody podpůrných vektorů.

Klíčová slova

Finanční analýza, finanční ukazatele, metoda podpůrných vektorů, rozhodovací stromy, shluková analýza, metoda hlavních komponent.

Obsah

1	Úvod a cíl práce	13
1.1	Úvod.....	13
1.2	Cíl práce.....	13
2	Literární přehled	14
2.1	Strojírenský průmysl v EU	14
2.2	Finanční situace podniku	17
2.3	Finanční analýza	17
2.3.1	Definice, význam a cíle finanční analýzy	19
2.3.2	Uživatelé finanční analýzy	19
2.3.3	Analýza absolutních ukazatelů	20
2.3.4	Analýza poměrových ukazatelů.....	21
2.4	Modely hodnotící finanční zdraví podniku	27
2.4.1	Vybrané studie využívající metodu podpůrných vektorů a rozhodovacích stromů.....	28
3	Materiál a metodika	31
3.1	Data mining	31
3.2	Klasifikace	34
3.2.1	Metoda podpůrných vektorů (SVM)	37
3.2.2	Rozhodovací stromy	38
3.3	Shluková analýza	39
3.4	Metoda hlavních komponent.....	43
4	Výsledky práce	45
4.1	Výběr proměnných	45
4.2	Základní statistické údaje.....	45
4.2.1	Základní statistické údaje nejlepších a nejhorších společností.....	51
4.3	Shluková analýza	57
4.4	Vyhodnocení predikce, testování přesnosti modelu	64

4.4.1	Výsledky pro rok 2013.....	65
4.4.2	Výsledky pro rok 2012.....	69
4.4.3	Výsledky pro rok 2011.....	73
5	Závěr a diskuze	78
6	Literatura	81

Seznam obrázků

Obr. 1	Sektorové složení v EU a ve Spojených státech v roce 2011	15
Obr. 2	Vývoj HDP v letech 2004 až 2014 v mld. EUR	16
Obr. 3	Schéma postupu při dolování dat	33
Obr. 4	Ilustrace klasifikace pomocí diskriminačních funkcí	34
Obr. 5	Dvě možné hraniční přímky	38
Obr. 6	Správné rozdělení dat s vyznačenými podpůrnými vektory x_1, x_2 a x_3	38
Obr. 7	Rozhodovací strom pro rozhodnutí o udělení hypotéky	39
Obr. 8	Nejčastěji užívané metriky shlukování	41
Obr. 9	Příklady dendrogramu nejčastěji užívaných metod shlukování	42
Obr. 10	Graf 50 korelovaných pozorování	43
Obr. 11	Graf 50 pozorování po transformaci na hlavní komponenty	44
Obr. 12	Celý dendrogram pro rok 2011	58
Obr. 13	Dendrogram na základě dat z pravého konce pro rok 2011	59
Obr. 14	Dendrogram na základě dat z levého konce pro rok 2011	60
Obr. 15	Celý dendrogram pro rok 2012	60
Obr. 16	Dendrogram na základě dat z levého konce pro rok 2012	61
Obr. 17	Dendrogram na základě dat z pravého konce pro rok 2012	62
Obr. 18	Celý dendrogram pro rok 2013	62
Obr. 19	Dendrogram na základě dat ze středu diagramu pro rok 2013	63
Obr. 20	Dendrogram na základě dat z pravého konce pro rok 2013	64
Obr. 21	Dendrogram na základě dat z levého konce pro rok 2013	64

Obr. 22	Klasifikace pomoci DT pro rok 2013	65
Obr. 23	Klasifikace pomoci DT pro rok 2012	69
Obr. 24	Klasifikace pomoci DT pro rok 2011	74

Seznam tabulek

Tab. 1	Počet zaniklých podniků ve vybraných státech EU	16
Tab. 2	Predikční přesnosti SVM, NN, MDA a Logit pro data použitá v Min a Lee 2005	29
Tab. 3	Predikční přesnosti DT a jiných metod pro data použitá v Li, Sun a Wu 2010	30
Tab. 4	Predikční přesnosti jednotlivých metod při odlišné selekci proměnných pro data v Lin a McClean 2001	30
Tab. 5	Kontingenční tabulka	35
Tab. 6	Přehled použitých proměnných při klasifikaci	45
Tab. 7	Statistické charakteristiky pro ukazatele zadluženosti	46
Tab. 8	Statistické charakteristiky pro ukazatele likvidity	47
Tab. 9	Statistické charakteristiky pro ukazatele rentability	48
Tab. 10	Statistické charakteristiky pro ukazatele aktivity	50
Tab. 11	Skupina nejziskovějších společností	51
Tab. 12	Skupina nejméně ziskových společností	52
Tab. 13	Statistické charakteristiky pro skupinu nejziskovějších společností	52
Tab. 14	Statistické charakteristiky pro skupinu nejméně ziskových společností	54
Tab. 15	Podíl komponent na variabilitě souboru 2013	57
Tab. 16	Podíl komponent na variabilitě souboru 2012	57
Tab. 17	Podíl komponent na variabilitě souboru 2011	58
Tab. 18	Kontingenční tabulka pro DT model - absolutní hodnoty pro rok 2013	66

Tab. 19	Kontingenční tabulka pro DT model – relativní vyjádření pro rok 2013	66
Tab. 20	Míry hodnocení úspěšnosti klasifikace DT model pro rok 2013	67
Tab. 21	Kontingenční tabulka pro SVM (RBF ANOVA) model – absolutní hodnoty pro rok 2013	67
Tab. 22	Kontingenční tabulka pro SVM (RBF ANOVA) model – relativní vyjádření pro rok 2013	67
Tab. 23	Míry hodnocení úspěšnosti klasifikace SVM (RBF ANOVA) model pro rok 2013	68
Tab. 24	Kontingenční tabulka pro SVM (polynom) model – absolutní hodnoty pro rok 2013	68
Tab. 25	Kontingenční tabulka pro SVM (polynom) model – relativní vyjádření pro rok 2013	68
Tab. 26	Míry hodnocení úspěšnosti klasifikace SVM (polynom) model pro rok 2013	69
Tab. 27	Kontingenční tabulka pro DT model – absolutní hodnoty pro rok 2012	70
Tab. 28	Kontingenční tabulka pro DT model – relativní vyjádření pro rok 2012	71
Tab. 29	Míry hodnocení úspěšnosti klasifikace DT model pro rok 2012	71
Tab. 30	Kontingenční tabulka pro SVM (RBF ANOVA) model – absolutní hodnoty pro rok 2012	71
Tab. 31	Kontingenční tabulka pro SVM (RBF ANOVA) model – relativní vyjádření pro rok 2012	72
Tab. 32	Míry hodnocení úspěšnosti klasifikace SVM (RBF ANOVA) model pro rok 2012	72
Tab. 33	Kontingenční tabulka pro SVM model (polynom) – absolutní hodnoty pro rok 2012	72
Tab. 34	Kontingenční tabulka pro SVM model (polynom) – relativní hodnoty pro rok 2012	73

Tab. 35	Míry hodnocení úspěšnosti klasifikace SVM (polynom) model pro rok 2012	73
Tab. 36	Kontingenční tabulka pro DT model – absolutní hodnoty pro rok 2011	75
Tab. 37	Kontingenční tabulka pro DT model – relativní vyjádření pro rok 2011	75
Tab. 38	Míry hodnocení úspěšnosti klasifikace DT model pro rok 2011	75
Tab. 39	Kontingenční tabulka pro SVM model (RBF ANOVA) – absolutní hodnoty pro rok 2011	76
Tab. 40	Kontingenční tabulka pro SVM model (RBF ANOVA) – relativní vyjádření pro rok 2011	76
Tab. 41	Míry hodnocení úspěšnosti klasifikace SVM (RBF ANOVA) model pro rok 2011	76
Tab. 42	Kontingenční tabulka pro SVM model (polynom) – absolutní hodnoty pro rok 2011	76
Tab. 43	Kontingenční tabulka pro SVM model (polynom) – relativní hodnoty pro rok 2011	77
Tab. 44	Míry hodnocení úspěšnosti klasifikace SVM (polynom) model pro rok 2011	77
Tab. 45	Celková správnost vybudovaných modelů pro všechna sledovaná období	80
Tab. 46	Celková přesnost SVM ve vybraných studiích	80

1 Úvod a cíl práce

1.1 Úvod

Predikce finanční situace podniku je velmi důležitým tématem po celá desetiletí ať už v akademické či praktické oblasti podnikových financí. Znalost finanční situace podniku je důležitá nejen pro samotné akcionáře, věřitele a vrcholový management daného podniku při jejich rozhodování, ale i pro širší okolí, neboť finanční tíseň podniku (zejména pokud jde o větší množství společností ve stejném období) s sebou přináší i takové problémy jako je například nezaměstnanost. Existuje proto neustálá poptávka po stále přesnějším a stabilnějším nástroji pro predikci finanční situace.

Není tedy divu, že se prognózou budoucího vývoje podniku zabývalo a stále ještě zabývá nemálo akademiků, kteří v průběhu času sestavili více či méně úspěšné predikční modely, přičemž právě mezi ty nejvýznamnější původní přístupy patří detekce bankrotu v časovém předstihu. Ačkoliv jsme schopni predikovat i jiné stavy společnosti, tak právě predikce bankrotu je v rámci skupiny modelů predikce finanční tísně nejrozšířenější a to zejména z důvodu toho, že se jedná o zcela jasnou a také právně podloženou situaci společnosti, oproti například detekci finanční tísně nebo rizika.

Alfou i omegou pro každého zpracovatele finanční analýzy podniku jsou účetní výkazy (zejména se jedná o rozvahu a výkaz zisku a ztrát), které po adekvátním zpracování mohou dávat informace nejen o finanční situaci podniku, ale i o jeho silných a slabých stránkách, popřípadě i o příležitostech a nebezpečích. Dnes existuje mnoho přístupů pro hodnocení finanční situace podniku, mezi ty primární patří jednorozměrné finanční ukazatele (například likvidity, aktivity, rentability atd.), další možností jsou pak pokročilejší algoritmy, pomocí kterých dokážeme hodnotit jak minulý vývoj, současnou situaci, ale dokonce i predikovat budoucí vývoj společnosti. Velmi časté v této oblasti ekonomické predikce jsou klasické statistické metody, jako je například logistická regrese či vícerozměrná diskriminační analýza. V průběhu let byly však tyto metody postupně vytlačovány a nahrazeny novějšími metodami, jedná se například o modely s neuronovými sítěmi nebo algoritmem podpůrných vektorů.

1.2 Cíl práce

Hlavním cílem této práce je vyhodnocení přesnosti vypracovaných modelů pro predikci bankrotu strojírenských společností v EU. Pro úspěšné naplnění tohoto cíle je třeba za použití klasifikačních a dalších statistických metod určit podobu modelu, a tedy definovat významné proměnné vstupující do modelování. Bude proto provedena ekonometrická a statistická verifikace. Část firem ze vzorku bude vyhrazena pro validaci a testování přesnosti klasifikačního modelu. Středem pozornosti této práce je pak relativně nová metoda podpůrných vektorů, dále je zapojena i shluková analýza a také rozhodovací stromy.

2 Literární přehled

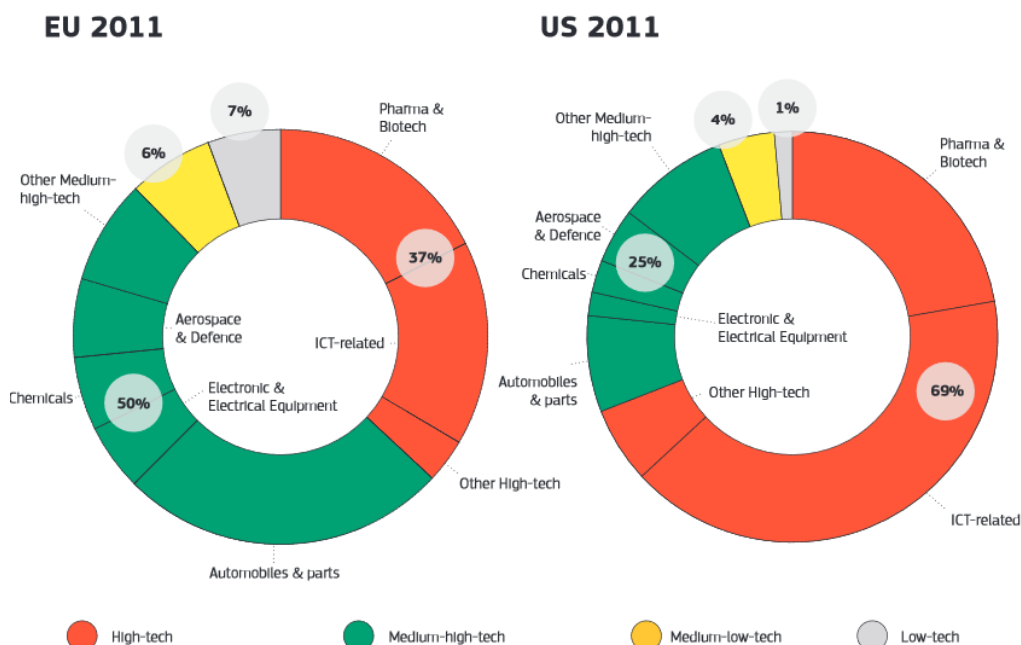
2.1 Strojírenský průmysl v EU

Strojírenství představuje technický obor, který patří mezi nejstarší a nejrozšířenější technické disciplíny a je možné ho dále rozdělit do několika odvětví.

1. *Těžké strojírenství* – zahrnující hutní a slévárenskou techniku. Patří sem například zařízení pro zpracování kovů, slévárny či přípravky.
2. *Střední strojírenství* – jenž produkuje stroje a zařízení pro obrábění a tvářební materiálů (sem bychom zařadili různé dodavatele náhradních dílů a komponentů či servis a modernizaci strojů apod.), automobilovou techniku a dodavatele pro automobilový průmysl i třeba zemědělské stroje aj.
3. *Lehké strojírenství* – kam spadají například televizory či jiná spotřební elektronika.
4. *Přesné strojírenství* – zahrnuje laserové technologie, digitální a telekomunikační přístroje, televize a mnohé další (Industry EU, 2012).

Strojírenství lze obecně označit jako nejznámější oblast výroby. Zejména v České republice má samozřejmou a dlouholetou tradici – dá se říci, že se jedná o odvětví průmyslu, které naši zemi proslavilo. Není tedy divu, že vzhledem k historickým, ale i zeměpisným souvislostem musí být náš průmysl vždy dostatečně silný v exportu (Technický týdeník, 2014).

Nejedná se však jen o Českou republiku, ale o celou Evropu (která koneckonců vedla vývoj průmyslové revoluce), jenž je velkým hráčem ve světovém průmyslu. Ze Zprávy o konkurenceschopnosti Evropské unie z roku 2013 vyplývá, že dle časových řad pokrývajících poslední desetiletí je EU držitelem mezinárodní konkurenční pozice (i když ne ve všech je přímo světovým vůdcem) například v letadlovém průmyslu, telekomunikacích, počítačových službách, strojním průmyslu (stroje pro všeobecné použití, obráběcí stroje, motorová vozidla atd.) a mnoha dalších oblastech.




Obr. 1 Sektorové složení v EU a ve Spojených státech v roce 2011

Zdroj: Vigier et al., 2014.

Světovou jedničkou je EU bezpochyby v oblasti obecně použitelných strojů a zařízení a i v oblasti obráběcích strojů, překonává zde jak Spojené státy, tak i Japonsko. Z hlediska přidané hodnoty jsou ze zemí EU největšími producenty bezesporu Německo, následované Itálií, Francií a Spojeným královstvím – ty tvoří dohromady zhruba 70 % z celkové přidané hodnoty v tomto odvětví v EU. Sílu Německa deklaruje například i to, že samotné přispělo v roce 2009 více než třetinově k vytvoření přidané hodnoty EU. Sektor obecně použitelných strojů a obráběcích strojů také významně přispívá k hrubému domácímu produktu Rakouska, České republiky, Švédska a Finska (Vigier et al., 2014).

Bohužel vývoj strojírenského průmyslu, stejně jako i ostatních, ovlivnila v posledním desetiletí zejména světová finanční krize, za jejíž vrchol můžeme označit roky 2008 až 2010. Tehdejší pokles ekonomiky a s tím spojené problémy pocítili všichni i nejsilnější hráč Německo. Právě v roce 2009 zažíval německý strojírenský průmysl nejhorší chvíle své historie – objem zakázek se poprvé propadl o nezapomenutelných 58 procent. Tehdejší propad německé ekonomiky byl tehdy označován jako nejdelší nepřetržitý od roku 1970 (Horáček, 2009).



Obr. 2 Vývoj HDP v letech 2004 až 2014 v mld. EUR

Zdroj: Eurostat, 2015.

Světová krize, která začala jako finanční krize, v dalších letech pokračovala jako ekonomická recese, a poté přešla do dluhové krize vlád, což nadále ohrožovalo pomalé a velmi křehké hospodářské ožívání. Běžným, ačkoliv bolestným, průvodním jevem zpomalování hospodářského růstu jsou potíže a bankroty podniků (Janáčková, 2010). Jak vyplývá z Tab. 1, tak například v České republice zaniklo od roku 2008 do roku 2013 více jak půl milionů podniků, přičemž nejvíce v roce 2012. Ve větších státech, například Itálii, za stejné období zaniklo skoro jeden a tři čtvrtě milionů podniků.

Tab. 1 Počet zaniklých podniků ve vybraných státech EU

	2008	2009	2010	2011	2012	2013
Německo ¹	-	261 297	253 123	255 206	254 009	237 509
Itálie	283 273	242 980	257 983	272 778	320 511	333 305
Francie	206 556	212 502	202 274	193 351	171 433	168 030
Spojené království	253 760	298 510	224 360	204 750	222 555	213 770
Česká republika	68 910	76 631	86 820	90 426	118 658	96 503

Zdroj: ČSÚ, 2016 (upraveno).

V současnosti se však ve strojírenském průmyslu projevuje růstový trend, přičemž ani v roce 2016 odborníci neočekávají žádné výrazné odchýlení od dosavadního vývoje. Ředitel svazu strojírenské technologie Oldřich Paclík se vyslovil na otázku, jaký očekává vývoj v českém strojírenství v roce 2016, následovně: „V roce 2016 očekáváme pokračování růstového trendu českého strojírenského průmyslu ve vazbě na současný příznivý vývoj globální ekonomiky. Hlavním faktorem růstu je z našeho hlediska příznivá situace v automobilovém průmyslu a na něj navazujícím subdoda-

¹ Bohužel z dat ČSÚ a databáze Eurostatu nebylo možné najít chybějící hodnotu zaniklých podniků v Německu z roku 2008.

vatelském sektoru. S ohledem na celkovou bezpečnostní situaci se domnívám, že posílí také obranný průmysl.“ Dále pak dodal, že české strojírenství je velice úzce spojeno s evropským a to zejména německým průmyslem, lze tedy očekávat, že pokud se bude dařit německému průmyslu, bude se dařit i tomu českému (Břeň, 2015).

2.2 Finanční situace podniku

V odborné literatuře je možno nalézt dva stavy podniku (jedná se o jakési protipóly) vymezující finanční situaci podniku – stav finančního zdraví či finanční tíseň daného podniku.

Pojem finanční zdraví byl přejat z anglosaské literatury a má vyjadřovat uspokojivou finanční situaci podniku. Za finančně zdravý můžeme považovat podnik, který:

- zhodnocuje vložený kapitál – zejména rentabilita (či výnosnost) v kombinaci s vyšší rizika je silně spjata s finančním zdravím podniku. Přičemž platí, že vyšší rentabilita má kladný vliv na finanční zdraví podniku, neboť vytvořený zisk společnosti slouží nejen ke splácení dluhů, ale představuje i zdroj financí pro další rozvoj společnosti (Pešková a Jindřichovská, 2012),
- je solventní – tedy nemá problémy se splácením závazků, neboť finančně zdravý podnik nesmí mít problémy s likviditou. Přičemž je nutno myslet nejen na krátkodobou likviditu, ale zajistit i dlouhodobou likviditu² (Pešková a Jindřichovská, 2012),
- vykazuje objektivní předpoklady pro pokračování podnikání i v budoucnu (Šiman a Patera, 2010).

Protikladem stavu finančního zdraví je finanční tíseň. Tento stav se naopak projevuje velmi vážnými problémy ve finančních tocích, ohrožuje likviditu a nelze jej vyřešit jinak než nějakou zásadní změnou struktury nebo činnosti společnosti. Do tohoto stavu se podnik může dostat nejen kvůli vysoké zadluženosti, nízké likviditě, ale i nízké provozní výkonnosti. Je nutné si však uvědomit, že finanční situace podniku se neustále mění, i podnik v současnosti finančně zdravý se může (např. změnou úročení nebo změnou devizových kurzů) dostat do stavu finanční tísně – je tedy nezbytně nutné neustále sledovat a analyzovat finanční situaci podniku (Pešková a Jindřichovská, 2012).

2.3 Finanční analýza

Metody finanční analýzy se postupně vyvíjely podle doby, ve které byly využívány. Asi nejvýznamnějším milníkem ve struktuře analýz byla doba, kdy se začaly hojně využívat počítače, ty totiž umožnily změny i v matematických postupech. Zpočátku

² Na dlouhodobou likviditu má nemalý vliv poměr cizích zdrojů k vlastním. Obecně platí, že čím je zadluženost menší, tím méně je podnik zranitelný, ale zároveň s tím bude pravděpodobněji vykazovat srovnatelně horší výsledky hospodaření.

spočívala finanční analýza v pouhém porovnávání absolutní změny v účetních výsledcích, pak se pozornost přesunula k rozvaze a výkazu zisku a ztrát, neboť se zjistilo, že jsou skvělým zdrojem informací ohledně úvěrové schopnosti podniků. Pojem finanční analýzy respektive tehdy ještě finanční bilance se v České republice poprvé objevil ve spise *Bilance akciových společností* od prof. dr. Pazourka v roce 1906. Teprve až po druhé světové válce a zejména po roce 1989 byla finanční bilance nahrazena angloamerickým pojmem finanční analýza (Růčková, 2015).

Současné moderní metody finanční analýzy slouží ke kompletnímu hodnocení finanční situace podniku. Nejenom že nám finanční analýza pomáhá jako zpětné zhodnocení, zda podnik dosáhl svých cílů, ale stejně tak pomáhá i při budoucím plánování zejména k rozhodování o investicích, k volbě optimální kapitálové struktury atd. (Knápková a kol., 2013). Podle hlediska způsobu práce s daty a také z hlediska času je možno metody finanční analýzy rozlišovat na (Kraftová, 2002):

- finanční analýzu fundamentální – má pragmatický a heuristický charakter, analytici v ní využívají zkušeností, intuice a expertních odhadů, bývá uplatňována zejména při velkých změnách podmínek, jež znemožňuje využití extrapolačních metod při technické finanční analýze.
- finanční analýzu kauzální – při tomto typu analýzy se zkoumají příčinně důsledkové vazby mezi jevy, přičemž tyto jevy mohou mít jak stochastický, tak i deterministický charakter. Velice známým příkladem této metody jsou pyramidové rozklady ukazatelů.
- finanční analýzu technická – je založena na matematicko-statistických metodách. Příkladem primárních metod je analýza vertikální (strukturální) a horizontální (trendová), ve které jde o kvantifikaci cyklických a trendových komponent s odlišením od náhodných odchylek.
- finanční analýzu komparační – bývá častým doplňkem technické analýzy. Jejím principem může být srovnávání s tzv. standardními hodnotami ukazatelů. Tato metoda bývá některými autory považována za univerzální metodu, jinými je naopak odsuzována (neboť je použitelná, jenom pokud si je analytik vědom všech specifik uvnitř i vně firmy).

Dále lze finanční analýzu rozdělit i podle závislosti na časové dimenzi na:

- finanční analýzu ex post – pracujeme s daty z minulosti (je tedy orientovaná retrospektivně), která jsou následně zpracována metodami finanční analýzy. Například se může jednat o výstup při technické finanční analýze, na který potom navazuje fundamentální analýza orientovaná ex ante.
- finanční analýzu ex ante – je orientovaná do budoucna (zpravidla jeden až tři roky, max. do pěti let), zpravidla se zde využívají predikční modely a to jak bonitní tak i bankrotní verze (Kraftová, 2002).

2.3.1 Definice, význam a cíle finanční analýzy

Existuje velké množství definic finanční analýzy. Dle Růčkové (2010, s. 9) je tou nejužitečnější ta, které říká, že „*finanční analýza představuje systematický rozbor získaných dat, která jsou obsažena především v účetních výkazech*“. Základ finanční analýzy je tedy v datech z účetních výkazů, mezi něž patří zejména rozvaha, výkaz zisku a ztrát a přehled o peněžních tocích v podniku. Dalším zdrojem pro analýzy jsou i různé zprávy vrcholového vedení podniku, výroční zprávy, zprávy auditorů, oficiální ekonomické statistiky a mnoho dalších (Knápková, 2013). Cenné informace mohou přinést i vnitropodnikové účetní výkazy, které sice nepodléhají jednotné právně závazné formě (méně vhodné pro mezipodnikové srovnávání), ale bývají sestavovány v častější frekvenci než například rozvaha a tím jsou výhodné pro sestavování časových řad (Růčková, 2015).

Účetnictví nám dává (za předpokladu správnosti prezentovaných výsledků podniku) poměrně přesné hodnoty peněžních údajů, tyto údaje se však vztahují pouze k jednomu okamžiku (jsou to poměrně izolované údaje), aby mohla sloužit jako zdroj pro kvalitní rozhodování, tak musejí být prvně podrobena finanční analýze (Růčková, 2015). Kislingerová (2010) podotýká, že v podnikové praxi (zejména u menších podniků) se stále setkáváme s názorem, že finanční analýza není nutná. Obvykle se v takovýchto podnicích rozhodování provádí pouze na základě účetních výkazů (běžného a minulého období). Toto podceňování finanční analýzy pak může vést ke špatným rozhodnutím, neboť tyto souhrnné údaje nemají dostatečnou vypovídací schopnost – neposkytují informace o silných a slabých stránkách, nebezpečích, příležitostech, ani o finanční situaci podniku.

2.3.2 Uživatelé finanční analýzy

Informace o finanční situaci podniku nezajímají jen finanční manažery, ale i mnoho jiných subjektů, které se dají rozdělit do dvou skupin: externí a interní uživatelé (Kislingerová 2010). Mezi externí uživatele patří:

- investoři – patří sem jak vlastníci (akcionáři) tak i ostatní investoři, kteří podniku poskytují kapitál. Zajímají se především o informace ohledně finanční výkonnosti podniku (rentabilitu), stabilitu a likviditu, aby věděli, jak je nakládáno se zdroji, které podniku poskytli. Vyhodnocují se vztah mezi rizikem a výnosností svojí investice – zejména o disponibilní zisk, na kterém závisí výplata dividend (Mulač a Mulačová, 2013).
- banky a jiní věřitelé – zkoumají zejména solventnost, likviditu a zadluženost potenciálního nebo již existujícího dlužníka. Podle výsledků analýz se rozhodují, za jakých podmínek úvěr poskytnou či raději neposkytnou vůbec. Věřitelé si mohou k informacím o finančním stavu podniku dopomoci i z Centrálního registru úvěrů ČNB, či portálu justice.cz apod. (Kislingerová 2010).
- stát a jeho orgány – stát sleduje prostřednictvím svých orgánů finančně-účetní data podniků nejen pro kontrolu plnění daňových povinností, ale také kvůli

rozdělování dotací či různým statistickým výzkumům atd. (Mulač a Mulačová, 2013).

- obchodní partneři – obdobně jako banky, tak i obchodní partneři (dodavatelé) sledují solventnost a zadluženost podniků. Nejedná se však jen o sledování krátkodobé stability podniku, ale i té dlouhodobé – každý podnik chce mít zajištěnou dlouhodobou plynulost svého chodu (Kislingerová 2010).
- konkurenční firmy – často porovnáváme vlastní dosažené výsledky s výsledky největších konkurentů, abychom tak odhalili jejich silné a slabé stránky a na základě těchto informací upevnili vlastní postavení na trhu. Sleduje se zejména výše tržeb, výše zásob, doba obratu zásob atd. (Mulač a Mulačová, 2013).

Za interní uživatele finanční analýzy lze označit:

- manažery – ti využívají informace o hospodaření pro svoji každodenní činnost (operativní a strategická rozhodnutí při řízení podniku). Díky přístupu k pravdivým i neveřejně dostupným informacím o společnosti mají ty nejlepší možnosti ke zpracovávání finanční analýzy (Kislingerová 2010).
- zaměstnance – ačkoliv běžní zaměstnanci si přímo netvoří finanční analýzy podniku, tak mají zájem na dlouhodobé stabilitě a prosperitě podniku, a to zejména pokud jsou finančně zainteresovány na hospodářském výsledku podniku (Mulač a Mulačová, 2013).

Tento výčet uživatelů není zcela úplný, o finanční situaci podniků se zajímají i další zájmové skupiny. Za další uživatele bychom mohli jmenovat analytiky, daňové poradce, burzovní makléře, odborové svazy, novináře a další (Mulač a Mulačová, 2013).

2.3.3 Analýza absolutních ukazatelů

Absolutní ukazatele, obsažené přímo v účetních výkazech, se využívají pro horizontální a vertikální analýzy. Při každé z těchto analýz je třeba dbát na srovnatelnost dat, které chceme vzájemně porovnávat – v rozvahách se dají nalézt stavy majetku a kapitálu vždy k jednomu určitému datu (jedná se o stavové veličiny), naopak ve výkazu zisku a ztrát a výkazu cash flow pracujeme s tokovými veličinami, jež ukazují výsledky za nějaké uplynulé období³. Při analýzách starších období je vhodné sledovat i to, zda nedošlo k nějakým změnám v metodice účetnictví (Kislingerová a kol., 2010).

Princip **horizontální analýzy** spočívá v pozorování změn v jednotlivých absolutních ukazatelích v časové posloupnosti. Na základě tohoto vývoje ukazatelů lze odvozovat vývoje trendů v daném podniku⁴. Přičemž změny v ukazatelích se dají

³ Tento rozdíl lze částečně odstranit například přepočtem stavovým položek.

⁴ Tento vývoj je však založen na předpokladu, že okolí firmy i sama firma se bude chovat v budoucnu stejně, jak tomu bylo doposud.

sledovat jak v absolutním tak i relativním vyjádření (Knápková a kol., 2013). Možný vzorec pro výpočet diference změny by vypadal následovně:

$$D_{t/t-1} = B_i(t) - B_i(t-1),$$

přičemž $D_{t/t-1}$ představuje změnu oproti minulému období a B_i je hodnota dané bilanční položky. Pro zjištění procentuální změny stačí pouze následující vzorec vynásobit hodnotou 100:

$$I_{t/t-1}^i = \frac{B_i(t) - B_i(t-1)}{B_i(t-1)}.$$

Vertikální analýzou účetních výkazů se zjišťuje jaký podíl (v %) má daná položka vzhledem k jedné zvolené základně, která je dána jako 100 %. Nejčastěji se volí jako základna suma aktiv či pasiv, popřípadě celkové náklady či výnosy v případě výkazu zisku a ztrát (Knápková a kol., 2013). Vzorec pro vertikální analýzu by vypadal následovně:

$$P_i = \frac{B_i}{\Sigma B_i}.$$

Kromě těchto rozborů účetních výkazů se mohou počítat i tzv. **rozdílové ukazatele**. Jako nejznámější z nich lze označit výpočet **čistého pracovního kapitálu**, pomocí kterého se hodnotí likvidita společnosti. Tento ukazatel pracuje se stejnými složkami rozvahy jako ukazatel běžné likvidity, nedává je však do poměru. Čistý pracovní kapitál udává, jakou část oběžného majetku máme financovanou z dlouhodobého kapitálu. Každý správně fungující podnik potřebuje mít kladný čistý pracovní kapitál, aby tím byla zajištěna nezbytná míra likvidity (Vochozka, 2011). Vzorec pro tento ukazatel se dá vyjádřit jako:

$$\text{čistý pracovní kapitál} = \text{oběžná aktiva} - \text{krátkodobé závazky}. \quad (1)$$

2.3.4 Analýza poměrových ukazatelů

Finanční analýza pomocí poměrových ukazatelů je v podnikové praxi velice oblíbená, neboť dává relativně rychlou odpověď na otázku finanční situace podniku. Princip této metody stojí na poměřování různých položek z rozvahy, výkazů zisků a ztrát či výkazů cash flow. Teoreticky se tak dá nadefinovat nepřeberné množství ukazatelů, kterým lze přiřadit i ideální hodnoty. Obecně se však osvědčilo využívat jen určité základní skupiny ukazatelů, rozdělené podle oblastí, kterými se zabývají. Jedná se především o ukazatele zadluženosti, rentability, likvidity a aktivity. Známé jsou i ukazatele kapitálového trhu, kterým se ale kvůli premise podniků obchodovatelných na burze nebudeme v této práci nikterak věnovat (Knápková a kol., 2013).

Ukazatele zadluženosti

Podniky mohou pro financování svých aktiv využívat buď vlastního kapitálu, nebo cizích zdrojů. Přičemž je neefektivní, aby vedení společnosti využívalo pouze jeden z těchto zdrojů (Knápková a kol., 2013). Firmy rády využívají „levnějšího“ cizího kapitálu⁵, je však nezbytně nutné volit optimální strukturu celkového kapitálu (teorie U-křivky) tj. minimum funkce průměrných nákladů na kapitál (Synek a kol., 2011). Nejzákladnějším ukazatelem skupiny ukazatelů zadluženosti je **celková zadluženost** (také nazývána jako věřitelské riziko), její doporučené hodnoty se pohybují v rozmezí 30–60 % (Knápková a kol., 2013). Vzorec pro tento ukazatel by vypadal následovně:

$$\text{celková zadluženost} = \frac{\text{cizí zdroje}}{\text{aktiva celkem}} \quad (2)$$

K měření zadluženosti můžeme využít i **koeficient samofinancování**, jedná se o doplňkový ukazatel ke zmíněnému ukazateli celkové zadluženosti – jejich součtem bychom měli dostat číslo velmi blízké hodnotě jedna (Růčková, 2015). Vzorec pro výpočet koeficientu samofinancování by se dal vyjádřit jako:

$$\text{koeficient samofinancování} = \frac{\text{vlastní kapitál}}{\text{aktiva celkem}} \quad (3)$$

Dalším zejména pro banky (či jiné věřitele) důležitým ukazatelem je **míra zadluženosti**, protože poukazuje na možné ohrožení věřitelských nároků. Pro správné vyhodnocení tohoto ukazatele je nutné ho sledovat z dlouhodobého hlediska (Knápková a kol., 2013). K jejímu vyjádření se využívá následující vzorec:

$$\text{míra zadluženosti} = \frac{\text{cizí zdroje}}{\text{vlastní kapitál}} \quad (4)$$

Není správné při finanční analýze zapomínat ani na hodnoty **úrokového krytí**. „Pokud má ukazatel hodnotu 1, znamená to, že podnik vytvořil zisk, který je dostatečný pro splácení úroků věřitelům, ale na stát v podobě daní a především vlastníka v podobě čistého zisku již nic nezbylo“ (Knápková a kol., 2013, s. 87). Za obecně doporučené hodnoty se uvádějí hodnoty pět a výše (Knápková a kol., 2013). K výpočtu výše úrokového krytí se využívá vzorec:

$$\text{úrokové krytí} = \frac{EBIT^6}{\text{nákladové úroky}} \quad (5)$$

⁵ Tento fakt souvisí například s nižším rizikem pro věřitele než pro akcionáře, dále s daňovým štítem i finanční pákou.

Dalším ukazatelem, který je už na bázi cash flow, je **doba splácení dluhů**. Tento ukazatel říká, za jakou dobu bude podnik schopen uhradit všechny dluhy, za předpokladu, že si udrží pořád stejnou úroveň tvorby cash flow jako v současnosti (Režňáková a kol, 2010). Vzorec pro tento ukazatel lze zapsat jako:

$$\text{doba splácení dluhů} = \frac{\text{cizí zdroje} - \text{rezervy}}{\text{provozní cash flow}}$$

Pro vyjádření vztahu mezi majetkovou a finanční strukturou podniku je možno počítat **krytí dlouhodobého majetku vlastním kapitálem**, popřípadě odvozenou verzi krytí dlouhodobého majetku dlouhodobými zdroji. Oba tyto ukazatelé souvisí s tzv. zlatými pravidly financování, tedy s obecným doporučením, že dlouhodobý majetek by měl být financován dlouhodobými zdroji – to však vždy záleží na konkrétní strategii podniku⁶. Pokud je hodnota tohoto ukazatele z dlouhodobého hlediska vyšší jak jedna (podnik používá vlastní kapitál ke krytí i oběžných aktiv), dává podnik přednost finanční stabilitě před možnými výnosy (Knápková a kol., 2013). Pro výpočet zmíněného ukazatele se využívá vztahu:

$$\text{krytí dlouhodobého majetku VK} = \frac{\text{vlastní kapitál}}{\text{dlouhodobý majetek}}$$

Ukazatelé rentability

Tato skupina ukazatelů bývá označována i jako ukazatelé výnosnosti, návratnosti či třeba ziskovosti. Obecně jsou tyto ukazatelé sestavovány jako poměr konečného efektu dosaženého vlastní činností k nějaké základně (vstupu), tou mohou být položky jak na straně aktiv tak i pasiv (Kislingerová a kol., 2010). Bohužel díky tomu bývají v podnikové praxi, ale i v odborných pramenech rozdílnosti v postupu výpočtu. Jedná se zejména o výši zisku, který může nabývat podoby EAT (čistý zisk), EBT (zisk před zdaněním), EBIT (zisk před odečtení daní a úroků), EBITDA (zisk před odečtením daní, úroků, odpisů a amortizací) či NOPAT (čistý provozní zisk po zdanění) apod. Pro vypočtené ukazatele rentability (ze všech možných variant zisku) se dá doporučit, aby byly v čase rostoucí (Růčková, 2015).

Nejčastěji sledovaným ukazatelem je podíl zisku k tržbám, podle toho jaký zisk do čitatele zvolíme, rozlišujeme **rentabilitu tržeb** a **ziskovou marži** (Palepu et al., 2013):

$$\text{rentabilita tržeb} = \frac{\text{EBIT}}{\text{tržby}} \quad (6)$$

$$\text{zisková marže} = \frac{\text{EAT}}{\text{tržby}} \quad (7)$$

⁶ Při agresivní strategii, kdy je výsledek ukazatele krytí dlouhodobého majetku vlastním kapitálem nižší než 1, podnik využívá ke krytí dlouhodobého majetku i krátkodobé zdroje (což je sice rizikovější, ale levnější). Naopak při konzervativní strategii (která je bezpečnější, ale dražší) je hodnota toho ukazatele vysoká, podnik totiž financuje dlouhodobými zdroji i krátkodobý majetek.

Oba tyto ukazatelé se dají využít pro hodnocení úspěšnosti podnikání, neboť se vztahují k tržbám, což je nejdůležitější položka výnosů u všech nefinančních společností (Knápková a kol., 2013). Dalším velmi významným ukazatelem je **rentabilita celkového kapitálu**, také známa jako rentabilita aktiv či produkční síla:

$$\text{rentabilita celkového kapitálu (ROA)} = \frac{\text{EBIT}}{\text{aktiva}}$$

Někdy počítaná i jako:

$$\text{rentabilita celkového kapitálu (ROA)} = \frac{\text{EBIT} \cdot (1-T)}{\text{aktiva}}, \quad (8)$$

kde T představuje daňovou sazbu. Prostřednictvím tohoto vzorce zjišťujeme tedy výkonnost podniku bez vlivu zadlužení, ale i bez vlivu daňového zatížení (Knápková a kol., 2013). Neméně významný je i výpočet **rentability vlastního kapitálu**, pokud by jeho výše byla trvale nižší, než je výnosnost cenných papírů garantovaných státem, nebude pro investory lákavé vkládat své finanční prostředky do takového podniku. Pro podnik je tedy vhodné, aby výše rentability vlastního kapitálu přesahovala míru bezrizikových cenných papírů, aby tak investorům plynula tzv. prémie za riziko (Růčková, 2015). Pro výpočet tohoto ukazatele se využívá následujícího vztahu:

$$\text{rentabilita vlastního kapitálu (ROE)} = \frac{\text{čistý zisk}}{\text{vlastní kapitál}}$$

Často se také zjišťuje **rentabilita úplatného kapitálu (ROCE)**, v některých publikacích označována i jako rentabilita investovaného kapitálu (Kislingerová a kol., 2010). Knápková a kol. (2013) pro výpočet ROCE využívá úplatný kapitál, tedy veškerý kapitál v podniku, jenž nese nějaký náklad (např. úrok). Pro výpočet ROCE se využívá tohoto vztahu:

$$\text{rentabilita úplatného kapitálu (ROCE)} = \frac{\text{zisk}}{\text{úplatný kapitál}}$$

Ukazatelé likvidity

Pokud chceme mít podnik solventní, tak musí být i likvidní. Tato skupina ukazatelů měří to, zda firma je schopna vyrovnávat včas své závazky. Je logické, že věřitelům by se líbily tyto hodnoty co nejvyšší, naopak je tomu u akcionářů, neboť je prokázáno, že vyšší míra likvidity se v podniku projevuje na úkor rentability (Růčková, 2015). Likvidita podniku se odvíjí i od postoje managementu k riziku, neboť čím je likvidita nižší (máme nižší stavy zásob i ostatních oběžných aktiv), tím je riziko pro podnik větší (Synek a kol., 2011).

V podnikové praxi se běžně sledují tři základní stupně likvidit. Všechny tyto ukazatele (v čitateli) vycházejí z oběžného majetku, jenž je v nich uspořádán z pohledu likvidity – od nejméně likvidních zásob, přes pohledávky až po samotné peníze (Vochozka, 2011). Jako nejpřesnější ukazatel z nich je možno označit **okamži-**

tu likviditu (nazývána i jako likvidita I. stupně, peněžní likvidita či hotovostní likvidita), neboť vyjadřuje schopnost podniku splatit své závazky v daný okamžik. Její ideální hodnoty by se měly pohybovat kolem 0,2⁷ (Vochozka, 2011). Někteří autoři např. Knápková a kol. (2013) uznávají jako „správné“ hodnoty i ty z intervalu 0,2 až 0,5. Vzorec pro stanovení tohoto stupně likvidity se dá vyjádřit jako:

$$\text{okamžitá likvidita} = \frac{\text{krátkodobý finanční majetek}}{\text{krátkodobé cizí zdroje}^8}$$

Druhým stupněm likvidity je **pohotová likvidita**, někdy nazývána i jako rychlá likvidita, neboť v sobě nezahrnuje zásoby, jakožto obecně méně likvidní aktiva oproti všem ostatním oběžným aktivům. Standardní hodnoty tohoto ukazatele by se měly vyskytovat mezi 1–1,5, přičemž právě hodnota jedna je brána jako prahová či kritická hodnota⁸ (Synek a kol., 2011). Vzorec pro pohotovou likviditu by vypadal následovně:

$$\text{pohotová likvidita} = \frac{\text{krátkodobé pohledávky} + \text{krátkodobý finanční majetek}^{11}}{\text{krátkodobé cizí zdroje}} \quad (9)$$

Třetím stupněm likvidity je **běžná (celková) likvidita**. Jedná se o relativně hrubý ukazatel, ale velmi často využívaný. Ačkoliv má obecně doporučované hodnoty v rozmezí 1,5 až 2,5, tak je vhodné srovnávat ho s odvětvovým průměrem (Synek a kol., 2011). Růčková (2015) udává, že některým firmám bývá doporučována hodnota od dvou výše. Pokud máme k dispozici údaje, že některé zásoby jsou již neprodejné, měly bychom je z výpočtu vyjmout, aby nám falešně nezvyšovali běžnou likviditu (Knápková a kol., 2013). K výpočtu běžné likvidity je využíváno tohoto vztahu:

$$\text{běžná likvidita} = \frac{\text{oběžná aktiva}}{\text{krátkodobé cizí zdroje}} \quad (10)$$

Pro hodnocení likvidity se dají použít i ukazatele na bázi cash flow například **likvidita z provozního cash flow**, který ukazuje, zda je podnik schopen hradit své závazky z vlastních vytvořených finančních prostředků (Managementmania, 2015). Vzorec pro výpočet tohoto ukazatele by vypadal následovně:

$$\text{likvidita z provozního CF} = \frac{\text{CF z provozní činnosti}}{\text{krátkodobé cizí zdroje}}$$

Ukazatelé aktivity

Ukazatelé aktivity informují o tom, jak je v podniku nakládáno a využíváno s jednotlivými částmi majetku. Můžeme při tom pracovat se dvěma formami ukazatelů, jedná se buď o počet obrátů (počet obrátů za rok) nebo o dobu obrátu (vyjadřovanou ve dnech). Pod vlivem sjednocování postupů v rámci EU se volí spíše využívání

⁷ Tyto ukazatelé likvidity jsou bezrozměrné veličiny.

⁸ Hodnoty i „zdravých“ podniků s vysoce agresivní strategií dosahují k hodnotám mezi 0,4–0,7 (Kislingerová a kol., 2010).

ukazatelů ve formě počtu obrátů, pokud si však chceme vyjádřit obchodní deficit⁹, tak se formě doby obratu nevyhneme (Vochozka, 2011).

Základním ukazatelem této skupiny je **obrat aktiv**, jenž udává, kolikrát se v daném podniku celková aktiva obrátí za rok. Ačkoliv vždy závisí na odvětví, ve kterém firma podniká, tak obecně je doporučováno, aby byla hodnota obratu aktiv alespoň rovna hodnotě jedna, neboť nižší hodnoty by poukazyvaly na neefektivní využívání majetku (Kislingerová a kol., 2010). Hodnotu obratu aktiv je možno zjistit pomocí následujícího vztahu:

$$\text{obrat aktiv} = \frac{\text{tržby}}{\text{aktiva}} \quad (11)$$

Pokud bychom se zajímali pouze o posouzení využívání investičního majetku, můžeme předešlý vzorec upravit na **obrat dlouhodobého majetku**. Po úpravě by vzorec vypadal následovně (Knápková a kol., 2013):

$$\text{obrat dlouhodobého majetku} = \frac{\text{tržby}}{\text{dlouhodobý majetek}}$$

Dalším podstatným ukazatelem je **obrat zásob**. Tento ukazatel vyjadřuje kolikrát je daná položka zásob v průběhu roku prodána a znovu naskladněna. V odborné literatuře se dá najít vícero návodů, jak tento ukazatel zkonstruovat, krom námi zvolené formy vzorce můžeme využít místo tržeb denní náklady či denní spotřebu (Kislingerová a kol., 2010):

$$\text{obrat zásob} = \frac{\text{tržby}}{\text{průměrný stav zásob}} \quad (12)$$

Nemělo by se také při hodnocení podniku zapomínat na výpočet **doby obratu pohledávek** a **doby obratu závazků**. Často důležitější než jejich samotná výše (ta je totiž specifická pro každý podnik, odvětví i trh) je jejich vzájemná provázanost. Pro správné fungování podniku je vhodné, aby byla doba obratu pohledávek kratší než doba obratu závazků. Jinak řečeno, aby podnik dříve inkasoval, než sám musí hradit své závazky – tím si podnik zajišťuje nejenom plynulý chod, ale i jistou likviditu (Knápková a kol., 2013). Výpočet těchto ukazatelů se provádí pomocí následujících vzorců:

$$\text{doba obratu pohledávek} = \frac{\text{průměrný stav pohledávek}}{\text{tržby}} * 360, \quad (13)$$

$$\text{doba obratu závazků} = \frac{\text{krátkodobé závazky}}{\text{tržby}} * 360. \quad (14)$$

⁹ Obchodní deficit se vyjádří jako rozdíl doby obratu pohledávek a doby obratu závazků.

2.4 Modely hodnotící finanční zdraví podniku

Těmito modely se rozumí soustavy účelově vybraných ukazatelů, přičemž se rozlišují bonitní a bankrotní modely. Mezi těmito dvěma skupinami modelů nejsou nijak přesně stanoveny hranice, obě skupiny se snaží dané společnosti přiřadit jednu číselnou charakteristiku, na jejímž základě by se dala posoudit finanční situace podniku. Toto rozdělení na bankrotní a bonitní modely vzniklo tedy podle toho, k jakému účelu byly jednotlivé modely vytvořeny (Růčková, 2015).

Bonitní modely mají za cíl určit, zda daná společnost spadá mezi ty „dobré“ či „špatné“ společnosti. *„Je proto zřejmé, že musí umožňovat srovnatelnost s jinými firmami“* (Růčková, 2015, s. 143). Naopak **bankrotní modely**, které vycházejí z premisy, že firmy vykazují po určitou dobu před bankrotem symptomy typické pro bankrot (zejména problémy s likviditou, s výší čistého pracovního kapitálu, rentabilitou celkového vloženého kapitálu atd.), nás mají informovat, zda sledovaná společnost není v dohledné době ohrožena bankrotem (Růčková, 2015).

Metod pro hodnocení finanční situace podniku existuje nesčetně, často si je banky či jiné instituce pečlivě chrání (je to jejich know how), ale ve všech hrají významnou roli finanční ukazatelé (Kislingerová a Hnilica, 2008). V rámci této práce bude věnována pozornost pouze přehledu nevýznamnějších bankrotních modelů. Mezi ty celosvětově neznámější modely se určitě řadí Altmanův model (1968) založený na diskriminační analýze¹⁰, kde byly testované subjekty rozděleny na nezbankrotované či v úpadku, přičemž oblasti mezi těmito dvěma skupinami označil jako šedou zónou vzhledem k chybám v klasifikaci. Diskriminační analýzu ve své práci využil i Beerman. Ten použil celkem 10 ukazatelů, nejdříve ověřil skrze jednorozměrnou analýzu jejich rozlišovací schopnost a pak použil diskriminační analýzu, aby všechny tyto ukazatele spojil do jedné lineární funkce (Martinič, 2008). Vochozka (2011) dodává, že predikční chyba této Beermanovy diskriminační funkce se s prodlužující se dobou neustále zvyšuje.

Známa, avšak v praxi málo oblíbená, je i Beaverova jednorozměrná diskriminační analýza z roku 1966. Nejedná se totiž o zcela komplexní model, neboť nedostaneme jen jednu hodnotu, pomocí níž bychom mohli určit finanční situaci podniku, ale každý použitý ukazatel zde má svou vlastní rozlišovací hodnotu. Tyto rozlišovací hodnoty jsou nastaveny tak, aby bylo minimalizováno chybné zařazení společnosti (Vochozka, 2011). Beaver při svých analýzách zjistil, že u ukazatele běžné likvidity či celkové zadluženosti jsou rozdíly mezi podniky prosperujícími a podniky ohroženými bankrotem největší. Dále vyvodil, že ukazatel čisté rentability celkového kapitálu a poměr cash flow/cizí zdroje jsou nejlepšími indikátory pro budoucí finanční vývoj, neboť u nich bylo nejmenší procento chybně zařazených podniků (Martinič, 2008).

Dalším významný model (podobný tomu Altmanovu) byl zkonstruován v roce 1977 na základě hodnot více jak 80 poměrových ukazatelů bankrotujících i prosperujících firem ve Spojeném království (Marinič, 2008). Jistou odlišnost to-

¹⁰ Jedná se o statistickou metodu, jejímž principem je roztrždit objekty do dvou či více definovaných skupin podle daných charakteristik (Růčková, 2010).

hoto Tafflerova modelu (který se ale vyskytuje pouze v původní verzi) spatřujeme v tom, že model nemá oblast šedé zóny. Podniky jsou v něm rozděleny na bonitní a bankrotní, přičemž hraniční hodnotou je nula (Vochozka, 2011).

Manželé Neumaierovi se rozhodli analyzovat vybrané bankrotní indikátory a z ukazatelů, jenž jsou ve většině modelů považovány za nejdůležitější, vytvořit index, který nazvali podle roku vzniku IN95 (data v něm jsou v roce 1994). Tento model jim umožnil zohledňovat odvětvová specifika (tehdy ještě podle odvětvové klasifikace OKEČ) pomocí různých vah pro jednotlivé ukazatele v indexu. IN95 byl ověřen na datech tisíců českých firem a jeho úspěšnost byla vyčíslena na 70 %. Později byl vytvořen IN99 se schopností správně vystihnout situaci firmy v 85 % případů, dále pak i IN01, který měl spojovat oba již zmíněné indexy (Neumaierová a Neumaier, 2002). V roce 2005 pak přišla další modifikace indexu na IN05, která změnila hodnotící intervaly tak, že se ve výsledku zúžila oblast šedé zóny (Vochozka, 2011).

2.4.1 Vybrané studie využívající metodu podpůrných vektorů a rozhodovacích stromů

Výčet výše zmíněných modelů není rozhodně úplný, mezi další, jenž významně ovlivnily postupy při hodnocení podniku, patří například model logistické regrese od Ohlsona (1980) či Zmijewského probit model (1984). Již popsané statistické metody nejsou jedinou možností pro predikci bankrotu. Tsakonas a kol. (2006), Chen a Du (2009) či Tsukada a Baba (1994) využili pro své práce neuronové sítě spadající do metod umělé inteligence. Shin, Lee a Kim (2005) ve své práci porovnávali přesnost nové metody podpůrných vektorů (SVM) a dotyčných neuronových sítí, jež dominovaly v devadesátých letech, a dokázali, že klasifikace se SVM má vyšší úroveň přesnosti. Také však dodali, že je stále potřeba dalšího výzkumu, zejména zkoumat vliv různých faktorů (kupříkladu volby jádra) na výkon výsledného systému. Právě studiím využívajícím metody podpůrných vektorů a rozhodovacích stromů (jejichž principy jsou blíže vysvětleny ve třetí kapitole) k predikci bankrotu bude věnována tato podkapitola.

Mnoho autorů se v posledních letech zabývalo porovnáváním predikčních schopností různých modelů. Min a Lee (2005) porovnávali výkon klasifikace více-rozměrné diskriminační analýzy (MDA), logistické regresní analýzy (Logit) a neuronových sítí (NN) spolu se SVM, kde využili RBF (radial basis function) jádra. Ve své práci využili vzorek 1888 společností (polovina z nich byla bankrotních), přičemž rozdělení dat bylo v poměru 60 % tréninkový set, 20 % dat pro validaci a zbylých 20 % pro testování. Jejich výsledky práce ukazují, že SVM předčí jiné stávající metody o několik procentních bodů.

Tab. 2 Predikční přesnosti SVM, NN, MDA a Logit pro data použitá v Min a Lee 2005

	SVM	NN	MDA	Logit
Tréninkový soubor	88,0132	85,2474	78,8079	79,8676
Validační soubor	83,0688	82,5397	79,1391	78,3069

Zdroj: Min a Lee, 2005, vlastní úprava.

Sami autoři ve své práci dále zdůrazňují, že dalším tématem pro budoucí práce by měla být volba příslušného jádra pro SVM, neboť se domnívají, že tato volba bude individuálně záviset na daném problému a datech.

Niknya, Darabi a Fard (2013) také porovnávali predikční schopnost modelů finanční tísně při využití SVM, vícerozměrné diskriminační analýzy a logistické regrese na datech z teheránské burzy cenných papírů z let 2007 až 2013. Z jejich práce plyne, že existuje významný rozdíl v průměrné přesnosti predikce z těchto tří modelů. Právě metoda SVM dosáhla nejvyšší přesnosti 93 %, s logistickou regresí dosáhli přesnosti 85 % a metoda MDA měla nejnižší přesnost necelých 82 %. Vyšší přesnosti při využití SVM oproti ostatním přístupům dosáhli ve své studii například i Ding, Song a Zen (2008), Min, Lee a Han (2006) či Huarng, Yu a Chen (2004).

Sun a Li (2012) ve své práci zkoumali, jaké výsledky získáme, pokud použijeme jedinou metodu klasifikace oproti využití celého ensmbu metod. Ve středu jejich zájmu byla právě metoda SVM. Ve svém experimentu založeném na čínských společnostech využili SVM klasifikátory s různými typy jádra včetně lineárního jádra, polynomického jádra (stupeň dva i tři), sigmoid a RBF jádra. Výsledky jejich práce ukazují, že při správném nastavení je SVM ensemble významně účinnější než jednotlivý SVM klasifikátor. Krom toho také zjistili, že při aplikaci individuálního SVM klasifikátoru se jako nejlepší volbou pro predikci jevila RBF-SVM v kombinaci s extrakční metodou postupné vícenásobné diskriminační analýzy.

Li, Sun a Wu (2010) ve své práci využívají k predikci krachu společnosti metodu rozhodovacích stromů¹¹ (DT) jakožto jednu z možných alternativ k současným populárním metodám (tj. metoda *k*-nejbližšího souseda, SVM atd.) Mezi výhody využití DT patří zejména jednoduchost získaných výsledků, snazší implementace, nelineární odhad, a také i to, že se jedná o neparametrickou predikci. V Tab. 3 jsou pro lepší přehlednost zaznamenány zjištěné průměrné přesnosti predikce při využití jednotlivých metod.

¹¹ Přesněji se jedná o CART (Classification and Regression Trees) algoritmus učení.

Tab. 3 Predikční přesnosti DT a jiných metod pro data použitá v Li, Sun a Wu 2010

Metoda	Průměrná přesnost (%)
DT	90,30
MDA	88,00
Logit	86,89
SVM	89,41
k-nejbližšího souseda	88,82

Zdroj: Li, Sun a Wu, 2010, vlastní úprava.

Jak je patrné z Tab. 3, tak na základě empirických výsledků na čínských společnostech překonala klasifikace pomocí DT metodu SVM pouze o necelé jedno procento. I Lin a McClean (2001) ve své studii porovnávají výkon statistických metod a metod strojového učení na datech 1133 společností z let 1980 až 1999¹². Přičemž srovnali i účinnost lidského úsudku (založeného na finančních teoriích, využitého i jinými vědci v dřívějších studiích) a statistické metody ANOVA.

Tab. 4 Predikční přesnosti jednotlivých metod při odlišné selekci proměnných pro data v Lin a McClean 2001

Metoda	Selekce č. 1 (Lidský úsudek)	Selekce č. 2 (ANOVA)
MDA	78,6	77,4
Logit	84,0	84,6
NN	87,5	88,1
DT	86,6	88,7

Zdroj: Lin a McClean, 2001, vlastní úprava.

Z Tab. 4 vyplývá, že metody strojového učení (NN a DT) dosahují v porovnání s ostatními možnostmi lepších výsledků, navíc při druhém typu selekce se přesnost modelů ještě zvýšila. Rozhodovací stromy jsou pro svoje vlastnosti a predikční schopnost oblíbenou volbou pro mnoho modelů, ze současných studií můžeme jmenovat například Kim a Upneja (2014) či Gepp a Kumar (2015).

¹² Data pro trénink jsou z let 1980 až 1990, data ze zbylých let byla použita pro testování modelu.

3 Materiál a metodika

V této práci se pracuje s daty z databáze Amadeus, přičemž se vychází z údajů od roku 2011 do 2013, neboť aktuálnější výsledky nebyly během zpracování této práce k dispozici v dostatečném rozsahu a úplnosti. Byly vybrány finanční údaje malých a středně velkých nefinančních společností, neboť v dřívějších pracích byla často diskutována výrazně odlišná kapitálová struktura finančních společností nebo jejich vyšší zadluženost – je zde snaha o homogennější datový soubor.

Do práce bylo náhodným výběrem zařazeno celkem 51 společností, které v roce 2014 lze považovat již za zbankrotované, a dalších 902 aktivních společností z EU. Tato získaná data byla využita pro klasifikaci ve třech stupních – tréninkový, validační a testovací set v poměru 30/30/40 %. Takovéto rozdělení bylo využito například ve studii Klepáče a Hampela (2016). Pracuje se tedy ve třech krocích. Tím prvním je učení modelu, poté následuje validace a nakonec přichází samotné testování přesnosti na testovacích datech – přičemž ve všech těchto krocích využíváme vždy náhodné výběry pro tyto tři dílčí skupiny dat.

Při zpracování dat se vychází zejména z metodiky použité v článku Klepáč a Kamarýtová (2015) a Klepáč a Hampel (2016). Výpočty byly prováděny v softwaru R 3.1.1, pomocí doplňku Rattle. Postup této práce by se tedy dal shrnout do několika následujících kroků:

1. získání finančních údajů aktivních a zbankrotovaných firem z databáze Amadeus v dostatečném množství,
2. příprava dat na modelování,
 - a. výpočet hodnot jednotlivých ukazatelů,
 - b. rozdělení souboru dat na tréninkový, validační a testovací set,
3. shluková analýza a redukce dimenze dat,
4. klasifikace společností na zbankrotované a aktivní pomocí rozhodovacích stromů a metody podpůrných vektorů,
5. srovnání výkonu klasifikačních metod bankrotu na testovacím souboru dat pomocí kontingenční tabulky.

Všechny metody, které budou v práci využity (metoda hlavních komponent, shluková analýza, klasifikační metoda podpůrných vektorů) patří do vícerozměrných statistických technik a obecně spadají do skupiny data minigových přístupů neboli metod dolování dat.

3.1 Data mining

Pro účel této práce je nejdůležitější získaná data vhodným způsobem zpracovat na adekvátní výstup. „Složitější požadavky na analýzy jsou řešeny prostřednictvím technologií dolování dat (data miningu)“ (Tvrdíková, 2008, s. 116). Dolování dat má

široké pole využití, v komerční sféře se začalo prosazovat zejména v posledních dvou desetiletích (díky rozvoji vědy a technologie, jež tento proces umožnily). Cílem data miningu je (ať už automaticky nebo jen poloautomaticky) analyzovat data a nalézat v nich podstatné informace o vzájemných vztazích a souvislostech, které nebyly doposud známy (Novotný a kol., 2005). Obecně lze úlohy dolování dat rozdělit dle Novotného a kol. (2005) na¹³:

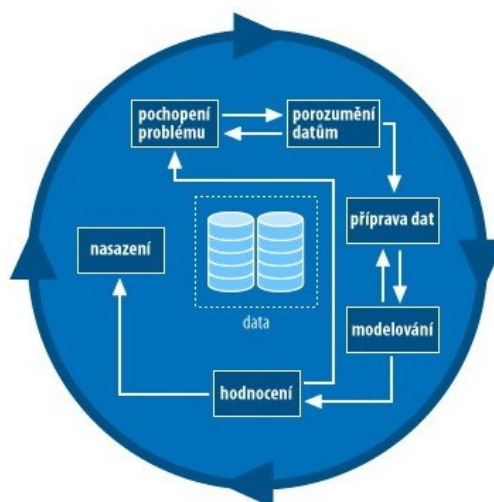
- a. **Explorační analýzy dat** – jejichž podstatou je prozkoumat data a to bez nějakých předcházejících znalostí, aby tak nedocházelo k ovlivnění už během hledání. U těchto úloh se dají využít různé grafické metody či speciální techniky.
- b. **Deskriptivní úlohy** – popisují celou datovou množinu, typickým příkladem je metoda shlukování popsaná blíže v Kapitole 3.3.
- c. **Prediktivní úlohy** – podstatou je předpovědět hodnotu dané veličiny na základě znalosti hodnot ostatních veličin. Přičemž predikce v dolování dat je nejčastěji prováděna klasifikací případů do tříd (více o klasifikaci v Kapitole 3.2).
- d. **Hledání vzorů a pravidel** (tzv. hledání nuggetů) – úloha na hledání vztahů a vzorů chování. Tento typ nalezneme třeba v bankovníctví, kde se provádí detekce vzorů naznačujících provádění operací praní špinavých peněz.
- e. **Hledání podle vzorů** – zde se jedná také o hledání vzorů v datech. Na rozdíl od předchozích úloh se hledá dle předem definované šablony. Jako příklad bychom mohli jmenovat rozpoznávání obrázků a textů.

Ať se jedná o jakoukoliv úlohu, tak se proces dolování dat dá rozdělit do šesti základních kroků (Novotný a kol, 2005 a Procházka, 2012):

1. *pochopení problému* – prvním krokem je definice problému a jasné stanovení cíle,
2. *výběr dat* – pak přichází definování zdrojů,
3. *příprava dat* – časově náročná část zejména pokud máme stovky (nebo i tisíce) proměnných, které mají vstupovat do modelu,
4. *modelování* – využití statistických i nestatistických nástrojů pro vytvoření matematických modelů,
5. *hodnocení* – konečné hodnocení modelů (ověřování správnosti modelů),
6. *nasazení* – posledním krokem je samotné zprovoznění modelu¹⁴.

¹³ Existuje mnoho různých členění úloh dolování dat, pro potřeby této práce jsme však vybrali jen jediné.

¹⁴ Procházka (2012) zdůrazňuje, že je nutné modely neustále udržovat aktivní, protože závislosti se v čase mohou měnit, proto proces po těchto šesti krocích nekončí, ale začíná se cyklicky opakovat.



Obr. 3 Schéma postupu při dolování dat

Zdroj: Procházka, 2012.

Dolování dat má tedy za cíl řešení nějakého konkrétního problému či nalezení cesty k vylepšení procesu. Je nutné si cíl správně definovat, neboť na jeho základě si připravujeme data. Nemalou pozornost si zaslouží i samotná příprava dat, ta musí být úplná, očištěná od chyb a v případě využívání různých formátů musejí být před aplikací metod sjednocena (Tvrdíková, 2008). Kvůli možnosti srovnání hodnot, jež mají různé veličiny, se provádí například centrování (kdy se odečte průměr) či normalizování¹⁵ (vztažení hodnoty proměnné k předem formulované normě), tento postup nám z původních hodnot udělá hodnoty bezrozměrné, které pak následně lze využít k výpočtům nějakého sumarizujícího parametru (Holčík, 2012).

Dnes už je k dispozici velké množství metod, které se využívají při budování modelu dolování dat, mezi ty nejčastěji užívané se řadí (Tvrdíková, 2008):

- analýza vztahů (asociační algoritmus pro odvozování pravidel typu „když X tak Y“),
- klasifikace (diskriminační analýza, logistická regresní analýza, rozhodovací stromy, neuronové sítě),
- segmentace – shlukování (shluková analýza, genetické algoritmy, Kohonenovy mapy),
- predikce časových řad (Boxova-Jenkinsova metodologie).

Přičemž Tvrdíková (2008) dodává, že zpravidla se nejlepších výsledků dosahuje kombinací různých přístupů.

¹⁵ Respektive standardizování, tedy vztažení centrované hodnoty k nějaké určité hodnotě (často ke směrodatné odchylce).


3.2 Klasifikace

Cílem klasifikace je rozdělit danou množinu objektů, jevů nebo procesů na konečný počet podmnožin podle jejich společných (podobných) vlastností¹⁶. Přičemž každý z objektů, jevů či procesů (dále již jen obecně objektů) se musí přiřadit do nějaké klasifikační třídy¹⁷, ale zároveň nesmí žádný z objektů spadat do dvou a více tříd zároveň, aby byla klasifikace úplná. V souvislosti s algoritmy užívanými při klasifikaci se rozlišuje:

1. **učení s učitelem** – charakteristickým znakem učení s učitelem je dostupnost tréninkových dat, tento datový soubor v sobě obsahuje informace o předpokládané správné klasifikaci. Tuto skupinu může dále dělit na učení s dokonalým nebo nedokonalým učitelem (Holčík, 2012).
2. **učení bez učitele** – kdy nám není předem známa příslušnost žádného z objektů a často ani počet tříd. Oproti učení s učitelem, zde není tréninková množina k dispozici. Typickým příkladem je shlukování popsané blíže v Kapitole 3.3 (Holčík, 2012 a Řezanková a kol., 2007).

Klasifikaci lze provádět několika následujícími způsoby.

- a) **Pomocí diskriminačních funkcí** – diskriminační funkce vyjadřují míru příslušnosti daného objektů do jednotlivých tříd, přičemž daný objekt se zařadí do takové třídy, pro kterou je tato příslušnost maximální. Tento princip je ilustrován na následujícím Obr. 4, kde neznámý objekt bude zatříděn do první třídy, neboť jeho míra příslušnosti g_1 je větší než u g_2 (Janoušková, Holčík a kol., 2015).



Obr. 4 Ilustrace klasifikace pomocí diskriminačních funkcí

Zdroj: Janoušková, Holčík a kol., 2015.

- b) **Pomocí etalonů klasifikačních tříd** – další možnost jak vymežit prostor jednotlivých klasifikačních tříd je pomocí polohy reprezentativních obrazů,

¹⁶ Tyto vlastnosti určují tzv. klasifikační kritéria, podle kterých se pak klasifikace provádí.

¹⁷ Klasifikační třídu tvoří ty objekty, které mají podobné vlastnosti.

tzv. etalonů. „Tímto způsobem popisu je pak nejčastěji vázána klasifikace podle minimální vzdálenosti, resp. maximální podobnosti“ (Holčík, 2012, s. 12). Mezi možné příklady metrik patří Euklidova, Hammingova, Minkovského metrika a další (Holčík, 2012).

- c) **Vymezením hraničních ploch** – klasifikace pomocí hranic bývá označována jako nejvíce intuitivní typ klasifikace, protože nakreslení čáry (hranice resp. hraniční plochy) bývá většinou první možností řešení, když nám dá někdo obrázek se dvěma skupinami bodů k rozdělení (Janoušková, Holčík a kol., 2015). Nemusí se však vždy jednat o prostou přímku, ta je jen speciálním lineárním případem v dvojrozměrném prostoru (obecně se zde jedná o křivku), může se jednat třeba o rovinu (v trojrozměrném prostoru) atd. (Holčík, 2012). Jako možné metody této skupiny lze jmenovat:
- metodu nejmenších čtverců* – kromě stanovování koeficientů hraničních funkcí je i hojně využívána při řešení regresních úloh. Kritériem je zde minimalizace sumy druhých mocnin (sumy čtverců) chyb (Holčík, 2012).
 - jednovrstvý perceptron* – jedná se o metodu zpracování dat inspirovanou nervovou soustavou – tzv. neuronové sítě, jejíž základní strukturou je právě jednovrstvý perceptron (Holčík, 2012). Neuronové sítě se doporučuje používat v úlohách, kde značnou roli v modelování hraje náhoda a kde jsou deterministické závislosti tak složité, že je nedokážeme oddělit a analyticky identifikovat. Například v oblasti investičního modelování (Dostál a kol., 2005).
 - fisherovu lineární diskriminaci* – jedná se o metodu pro lineární klasifikaci dat. Tato metoda v sobě kombinuje dvě kritéria: maximalizaci vzdálenosti centroidů a zároveň i minimalizaci variability uvnitř skupiny (Janoušková, Holčík a kol., 2015).
 - metodu podpůrných vektorů* – jedná se o metodu, jež se dá využít v mnoha rozličných klasifikačních třídách (Holčík, 2012). Tato metoda bude rozebrána o něco podrobněji níže.

K hodnocení úspěšnosti klasifikace může být využita *kontingenční tabulka* (často označována jako *matice změn* či *konfúzní matice*), jež může pro případ klasifikace podniků vypadat následovně:

Tab. 5 Kontingenční tabulka

Predikovaná skupina	Skutečná skupina		
	Aktivní		Bankrotní
	Aktivní	Skutečně pozitivní	Falešně pozitivní
Bankrotní	Falešně negativní	Skutečně negativní	

Zdroj: Klepáč a Hampel, 2015, vlastní úprava.

Tato kontingenční tabulka pro klasifikaci podniků na aktivní a zbankrotované vyjadřuje čtyři možné situace:

1. skutečně pozitivní (True Positives, TP) – jedná se o pozitivní shodu, tedy kolik aktivních podniků bylo správně klasifikováno jako aktivních,
2. falešně negativní (False Negatives, FN) – jsou výsledky falešně negativní, tedy kolik aktivních podniků bylo chybně klasifikováno jako zbankrotovaných,
3. falešně pozitivní (False Positives, FP) – zde se jedná naopak o falešně pozitivní výsledek, tedy kolik zbankrotovaných společností bylo chybně klasifikováno jako aktivních,
4. skutečně negativní (True Negatives, TN) – jedná se o negativní shodu, tedy kolik zbankrotovaných společností bylo správně klasifikováno jako zbankrotovaných (Janoušková, Holčík a kol., 2015).

Z těchto hodnot matice můžeme následně vypočítat následující míry hodnocení úspěšnosti klasifikace testovacích dat.

- *Celková správnost* – je dána podílem správně klasifikovaných subjektů ke všem subjektům (Klepáč a Hampel, 2016):

$$\text{celková správnost} = \frac{TP+TN}{TP+FP+FN+TN}. \quad (3)$$

- *Chyba I. typu* – hodnotí počet skutečně pozitivních výsledků, které byly klasifikovány jako skutečně negativní (Klepáč a Hampel, 2016):

$$\text{chyba I. typu} = \frac{FN}{TP+FN}. \quad (4)$$

- *Chyba II. typu* – ukazuje, kolik skutečně negativních výsledků bylo falešně označeno jako pozitivních (Klepáč a Hampel, 2016):

$$\text{chyba II. typu} = \frac{FP}{FP+TN}. \quad (5)$$

- *Senzitivita* – je poměr skutečně pozitivních pozorování k všem pozitivním případům (Klepáč a Kamarýtová, 2015):

$$\text{senzitivita} = \frac{TP}{TP+FN}.$$

- *Specificita* – je poměr správně negativních pozorování k všem negativním případům (Klepáč a Kamarýtová, 2015):

$$\text{specificita} = \frac{TN}{FP+TN}.$$

Na základě těchto vypočtených hodnot senzitivity a specifity můžeme sestavit tzv. ROC (Receiver Operating Characteristic) křivku a díky ní pak vyhodnotit přesnost klasifikace skrz oblast pod touto křivkou následovně (Klepáč a Hampel, 2016):

- hodnoty od 0,5 do 0,75 = přijatelná klasifikační schopnost,
- hodnoty od 0,75 do 0,92 = dobrá klasifikační schopnost,
- hodnoty od 0,92 do 0,97 = velmi dobrá klasifikační schopnost,
- hodnoty od 0,97 do 1,0 = perfektní klasifikační schopnost.

3.2.1 Metoda podpůrných vektorů (SVM)

Jedná se o relativně novou metodu prezentovanou Vapnikem (1999¹⁸), jejíž myšlenkou je převést původní prostor do vícedimenzionálního, kde už může jednotlivé třídy od sebe rozlišit lineárně. SVM lze využít pro klasifikaci dat, přičemž se jedná o metodu učení s učitelem. Oproti jiným metodám (Fisherova lineární diskriminace), metoda SVM umožňuje rozdělit úlohy na (Janoušková, Holčík a kol., 2015):


- lineární verzi pro lineárně separabilní¹⁹ třídy (v anglickém originále jako maximal margin classifier),
- lineární verzi pro lineárně neseparabilní třídy (anglicky support vector classifier),
- nelineární verzi (anglicky support vector machine).

Většinou se však (jak v angličtině, tak i v češtině) tyto případy nerozlišují a souhrnně se označují jako SVM. Další výhodou oproti již zmíněné Fisherově lineární diskriminaci je i to, že SVM nemá předpoklad normálního rozdělení. Naopak jako jistou nevýhodu bychom mohli označit nutnost stanovovat parametry (u lineárně neseparabilních úloh) či volbu jádra (nelineární verze), avšak i přes to zůstává v současnosti SVM jedou z nejčastěji využívaných metod (Janoušková, Holčík a kol., 2015).

Jak bylo již řečeno, tak principem metody je najít takovou hraniční přímku či nadrovinu, která by rozdělila všechny body. Při hledání této přímky se řídíme kritériem maximální vzdálenosti. Obr. 5 znázorňuje dvě možná rozdělení datového souboru (tzv. binární klasifikaci), vlevo vidíme méně přípustné řešení s jednoznačně menší mezerou oproti rozdělení vpravo, kde je optimální řešení s maximálním rozpětím. Podpůrné vektory (mající nenulové Lagrangeovy multiplikátory) jsou datové body ležící nejbliže k optimální dělící nadrovině popř. přímce viz Obr. 6 (Lipo, 2005).


¹⁸ První vydání této knihy bylo už v roce 1995.

¹⁹ Rozlišujeme množiny na separabilní či neseparabilní podle toho, zda se jejich obrazy nacházejí či nenacházejí v navzájem překrývajících se oblastech (Holčík, 2012).



Obr. 5 Dvě možné hraniční přímky

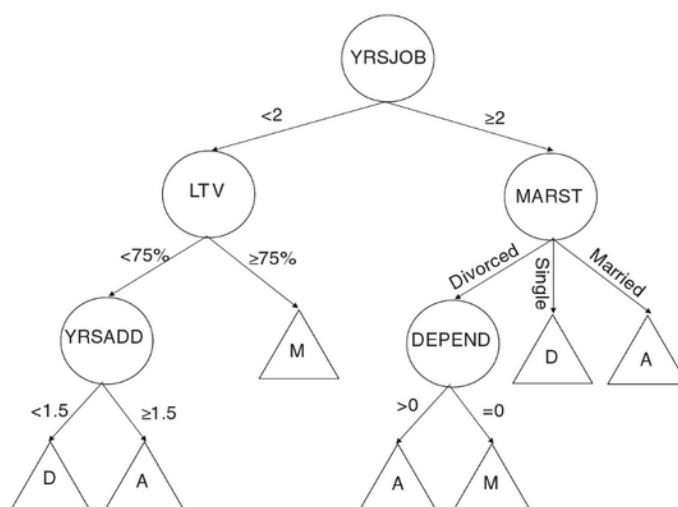
Zdroj: Lipo, 2005.

Obr. 6 Správné rozdělení dat s vyznačenými podpůrnými vektory x_1 , x_2 a x_3

Zdroj: Lipo, 2005.

3.2.2 Rozhodovací stromy

Rozhodovací stromy jsou v dnešní době velice oblíbenou metodou zejména díky své poměrně snadné interpretaci. Své uplatnění našly v oblastech, jako jsou finance, marketing, strojírenství či v medicíně. Jedná se o techniku, ve které jsou data zobrazena v podobě stromu, jenž je tvořen uzly a hranami, a která se používá ke klasifikaci objektů do předem nadefinovaných tříd (např. aktivní/zbankrotované či riskantní/neriskantní společnosti) na základě hodnoty atributů. Obr. 7 zobrazuje rozhodovací strom sloužící k usnadnění schvalování hypotečních žádostí založený na následujících datech: počet závislých osob (DEPEND), poměr úvěru k hodnotě nemovitosti (LTV), rodinný stav (MARST), poměr splátky ku příjmu (PAYING), úroková sazba (RATE), počet let na současně adrese (YRSAD) a počet let v současném zaměstnání (YRSJOB) (Rokach a Maimon, 2015).



Obr. 7 Rozhodovací strom pro rozhodnutí o udělení hypotéky
Zdroj: Rokach a Maimon, 2015.

Na základě daných proměnných rozhodovací strom klasifikuje žádosti buď na ty, které mají být schválené (A) nebo zamítnuté (D) či mají být zpracovány „ručně“ (M) na základě dalších doplňujících informací (Rokach a Maimon, 2015). Rozhodovací strom tedy rozděluje zdrojová data do segmentů, přičemž data zařazená do daného segmentu se vyznačují podobnými či shodnými vlastnostmi (Novotný a kol, 2005).

3.3 Shluková analýza

Shluková analýza dat patří mezi metody vícerozměrné statistické analýzy, jejím cílem je rozřídění daného počtu objektů do několika relativně homogenních skupin (shluků), přičemž se požaduje, aby si byly objekty uvnitř jednoho shluku co nejvíce podobné a objekty patřící do různých shluků si byly naopak podobné co nejméně. Předmětem shlukové analýzy je tedy popis a zobecňování vztahů ve skupině proměnných. Této vlastnosti se v ekonomické praxi hojně využívá pro rozdělování zákazníků do skupin či stanovování pravidel pro poskytování obchodních úvěrů. Další možné využití metody shlukové analýzy v kombinaci s ekonomickými ukazateli podniku, je při klasifikaci podniků dle předem stanovených parametrů a tedy využití při hodnocení výkonnosti a bonity podniků (Režňáková a kol., 2010).

Existuje hned několik způsobů shlukování, lze je rozdělit do dvou skupin na tzv. hierarchické či nehierarchické postupy. **Hierarchické postupy** jsou založeny na hierarchickém uspořádání objektů a jejich shluků. Ty se dají dále rozdělit dle postupu shlukování na aglomerativní a divizní shlukování. U aglomerativního shlukování se spojí do prvního hluku dva objekty, jejichž vzdálenost je nejmenší, pak se vypočte nová matice vzdáleností, v ní jsou však vynechány objekty z prvního shluku a naopak je tento shluk zařazen jako objekt. Celý tento postup se opakuje tak dlouho, dokud všechny objekty netvoří jeden velký shluk nebo dokud nezů-

stane předem zadaný počet shluků. Obrácený postup je při divizním shlukování, kdy se vychází z množiny všech objektů jakožto jednoho jediného shluku, a poté jeho postupným dělením získáváme systém shluků, až nakonec skončíme ve stádiu jednotlivých objektů. Mezi nejpoužívanější metody měření vzdálenosti mezi shluky patří (Meloun a Militký, 2006):

1. **Metoda nejbližšího souseda** – u této metody je postup založen na minimální vzdálenosti – naleznou se dva objekty oddělené nejkratší vzdáleností a ty se pak umístí do shluku. Další shluk je následně vytvořen přidáním třetího nejbližšího objektu. Tento postup se opakuje tak dlouho až jsou všechny objekty v jednom společném shluku (Meloun a Militký, 2006). Není vhodné používat tuto metodu pro kompaktní shluky přibližně stejné velikosti, hodí se spíše pro podlouhlé shluky (Kučera, 2008). Matematicky lze postup této metody zapsat následovně:

$$\rho_{NN}(C_i, C_j) = \min_{\substack{\mathbf{x}_p \in C_i \\ \mathbf{x}_q \in C_j}} \rho(\mathbf{x}_p, \mathbf{x}_q).$$

2. **Metoda nejvzdálenějšího souseda** – zde je kritérium postaveno naopak na maximální vzdálenosti, metoda bývá také někdy označována jako metoda úplného propojení, neboť jsou všechny objekty v obou shlucích vzájemně propojeny při maximální vzdálenosti, tedy minimální podobnosti (Meloun a Militký, 2006). Metoda nejvzdálenějšího souseda vytváří shluky přibližně stejné velikosti, zabráňuje vzniku zřetězených shluků (Kučera, 2008). Postup této metody se dá vyjádřit jako:

$$\rho_{FN}(C_i, C_j) = \max_{\substack{\mathbf{x}_p \in C_i \\ \mathbf{x}_q \in C_j}} \rho(\mathbf{x}_p, \mathbf{x}_q).$$

3. **Metoda průměrné vzdálenosti** – jak napovídá název, tak zde bude kritérium vzniku shluků průměrná vzdálenost, jedná se však o průměrnou vzdálenost všech objektů v jednom shluku ke všem objektům v druhém shluku (Meloun a Militký, 2006). Výhodou této metody je, že není příliš citlivá na možné statistické odchylky v datech, pokud máme objekty rozložené dle nějakého pravděpodobnostního rozdělení, tak přidáním dalších objektů nenarušíme získaný výsledek (Kučera, 2008). Matematicky bychom lze tento postup zapsat následovně:

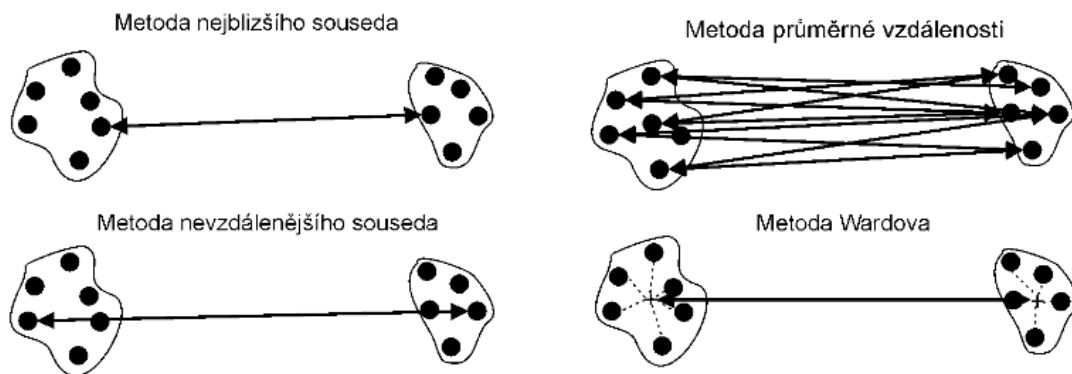
$$\rho_{GA}(C_i, C_j) = \frac{1}{P \cdot Q} \sum_{p=1}^P \sum_{q=1}^Q \rho(\mathbf{x}_p, \mathbf{x}_q).$$

4. **Wardova metoda** – metoda se snaží minimalizovat heterogenitu vzniklých shluků podle kritéria minimálního přírůstku vnitroskupinového součtu čtverců odchylek objektů od těžiště shluků. Postup této metody je takový, že se spočítá pro všechny dvojice přírůstek součtu čtverců odchylek, jenž vznikl jejich sloučením, a poté se spojí ty shluky, kterým odpovídá minimální hodnota tohoto přírůstku (Meloun a Militký, 2006). Jedná se o jakousi kombinaci postupů, při které je zapotřebí znát všechny obrazy obou množin stejně jako i znát re-

prezentativní obrazy. Matematicky se dá Wardova metoda vyjádřit jako (Holčík, 2012):

$$\rho_W(C_i, C_j) = \sum_{x_i \in C_i \cup C_j} \sum_{s=1}^n (x_{is} - \bar{x}_s)^2 - \left(\sum_{x_i \in C_i} \sum_{s=1}^n (x_{is} - \bar{x}_{1s})^2 + \sum_{x_i \in C_j} \sum_{s=1}^n (x_{is} - \bar{x}_{2s})^2 \right).$$

Tento vzorec říká, že vzdálenost mezi shluky je dána přírůstkem součtu čtverců odchylek mezi tzv. centroidem (obraz, který je určen nějakou významnou charakteristikou, nejčastěji průměrem či mediánem) a obrazy shluku vytvořené ze vstupních shluků (vstupních množin) C_i a C_j oproti součtu čtverců odchylek mezi obrazy a centroidy v obou množinách C_i a C_j . Dle Holčíka (2012) má navíc Wardova metoda tendenci vytvářet pevné, poměrně malé shluky, zhruba stejné velikosti.

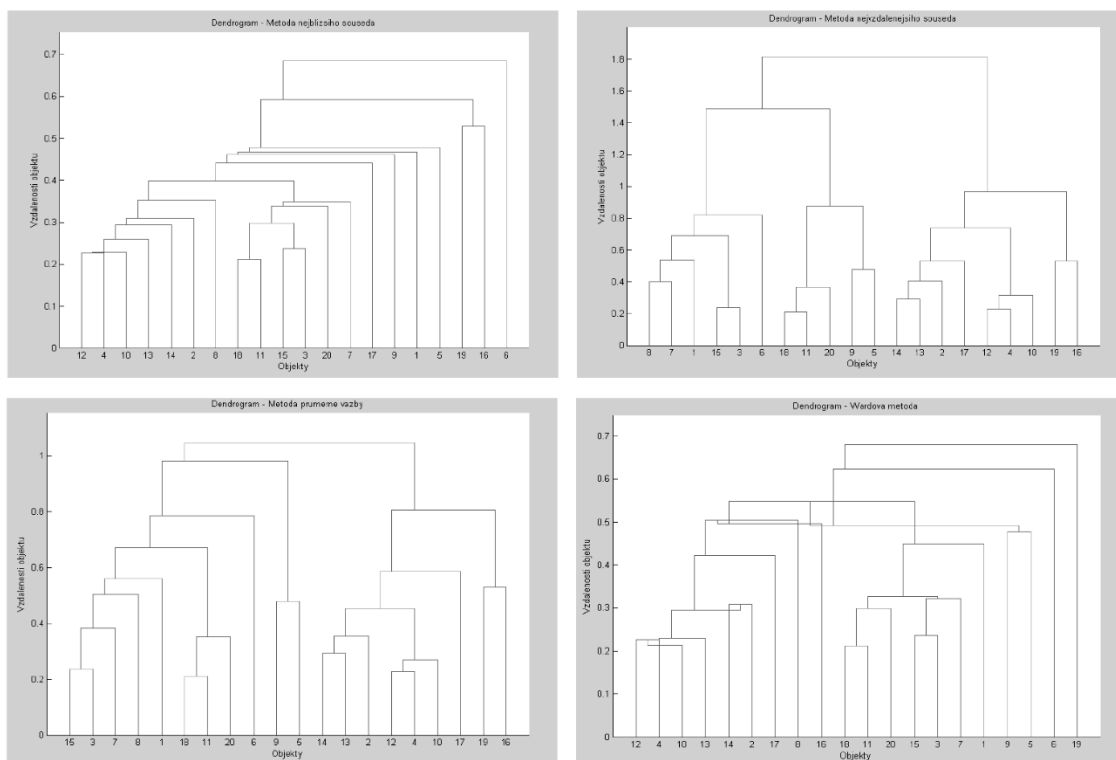


Obr. 8 Nejčastěji užívané metriky shlukování

Zdroj: Meloun a Militký, 2006.

Dle Režňákové a kol. (2010) je vhodné vyjádřit si stupeň shody mezi vlastnostmi objektů a výsledným shlukovacím procesem například Spearmanovým koeficientem korelace. Graficky lze postup hierarchického shlukování zobrazit formou dendrogramu – jedná se o stromový diagram, který v sobě zobrazuje vývojové vztahy formou větvičího se stromu. V Obr. 9 jsou ukázky dendrogramu pro všechny čtyři výše popsané nejznámější hierarchické metody²⁰.

²⁰ Pro proces shlukování zde byl použit program MATLAB, jako míra podobnosti zde byla použita euklidovská vzdálenost.



Obr. 9 Příklady dendrogramu nejčastěji užívaných metod shlukování
Zdroj: Režňáková a kol., 2010.

Druhou skupinu tvoří **nehierarchické postupy**. Řezanková a kol. (2007) podotýká, že panuje jistá neshoda s touto skupinou postupů. Někteří ji ztotožňují s negací výše popsaných hierarchických přístupů (proto název nehierarchické postupy), ale mnozí sem řadí pouze část z nehierarchických přístupů a jiní se raději tomuto termínu zcela vyhýbají a používají pro tuto skupinu název **metody rozkladu**. Jelikož existuje na tuto problematiku velké množství pohledů, budeme se věnovat jen jedné v literatuře nejčastěji zmiňované metodě ***k*-průměrů**²¹.


Tato metoda se používá v případech, kdy datový soubor v sobě obsahuje pouze kvantitativní proměnné. Výhodou této metody je, že při ní není potřeba pracovat s maticí vzdáleností – díky tomu je metoda vhodná i pro velké datové soubory s velkým počtem objektů. Nevýhodou však je, že tímto postupem dostaneme pouze lokálně optimální řešení závislé na pořadí objektů v datovém souboru (Řezanková a kol., 2007). Princip metody tkví v tom, že si sám uživatel (a to na základě svých vlastních věcných znalostí) určí, které z objektů mají tvořit tzv. zárodky nově vzniklých shluků, objekty se pak rozdělí do shluků podle jejich Eukleidovské vzdálenosti od těchto uživatelem určených objektů. Přičemž existuje vícero postupů jak zařazovat objekty do shluků, např. metoda sekvenčního prahu, paralelního prahu či optimalizace (Meloun a Militký, 2006).

²¹ Další známe metody jako například *k*-medoidů, *k*-modů, *k*-histogramů už jsou vlastně jen modifikace metody *k*-průměrů.

Všechny výše popsané metody shlukování lze označit jako tzv. tradiční metody. Vedle nich pak existuje skupina metod, které jsou označovány jako „novější přístupy“, mezi ně se dá dle Řezankové a kol. (2007) zařadit metody založené na mřížce, modely založené na hustotě (či kombinace obou těchto metod) nebo též shlukování podprostorů.

3.4 Metoda hlavních komponent


Hlavní myšlenkou metody hlavních komponent je snížit rozměrnost souboru dat, který se skládá z velkého počtu vzájemně se ovlivňujících proměnných, a to při největším možném zachování proměnlivosti původního souboru dat. Toho je dosaženo tím, že transformujeme novou sadu proměnných, které jsou nekorelované. Jolliffe (2002) ve své knize demonstruje tento proces transformace na nekorelované proměnné pomocí nereálného, avšak velice jednoduchého, příkladu. Předpokládejme, že x je vektor p náhodných pozorování. Pokud je $p=2$, dají se data vykreslit do dvourozměrného prostoru, jak je tomu na Obr. 10.



Obr. 10 Graf 50 korelovaných pozorování

Zdroj: Jolliffe, 2002.

Na prvním grafu je vidět značná variabilita u obou veličin, a to spíše ve směru x_2 než x_1 . Pokud se provede transformace těchto hodnot na hlavní komponenty z_1 a z_2 lze získat Obr. 11 (Jolliffe, 2002).



Obr. 11 Graf 50 pozorování po transformaci na hlavní komponenty
Zdroj: Jolliffe, 2002.

Z grafu je patrné, že existuje větší proměnlivost ve směru z_1 (a to větší jak u x_1 a x_2 na předchozím grafu), ale jen velmi malá ve směru z_2 . První hlavní komponenta z_1 tedy pokryla největší část proměnlivosti původních dat (Jolliffe, 2002). Zde se však jednalo o velmi zjednodušený případ jen se dvěma hlavními komponentami, pro jakékoliv větší množství hlavních komponent obecně můžeme říci, že první hlavní komponenta popisuje vždy největší část proměnlivosti (rozptylu) původních dat, druhá hlavní komponenta pak vyjadřuje největší část rozptylu, který není obsažen v první hlavní komponentě. První pár hlavních komponent tedy obvykle uchovává většinu proměnlivosti ze všech původních proměnných. O dalších možných hlavních komponentech lze pouze říci, že jejich celkový počet může být roven buď počtu objektů analyzovaných v dané úloze, nebo počtu sledovaných proměnných, přičemž se jedná vždy o číslo menší z těchto dvou nabízených variant. Volba správného počtu použitých hlavních komponent je nemálo významnou součástí komponentní analýzy. Obecně je doporučováno, aby jich bylo tolik, aby součet podílů proměnlivosti v nich byl dostatečně blízký hodnotě jedna (Janíček a kol., 2013).

Za hlavní komponenty se tedy dají označit lineární kombinace původních dat, avšak oproti původnímu souboru nejsou již korelované. Při výpočtu hlavních komponent se vychází z kovarianční matice, jejíž odhad se získá na základě netříděného souboru k vícerozměrných pozorování nebo sloučením výběrových kovariančních matic v podskupinách (Jarošová a Noskovičová, 2015).

Je vhodné začít analyzovat téměř každou vícerozměrnou úlohu metodou hlavních komponent. Nutné je si ale uvědomit, že ačkoliv se formálně dá popsat variabilita původních proměnných pomocí lineárních kombinací jednotlivých faktorů, obsahově se bude jednat o jinou interpretaci – pracuje se totiž s vytvořenými komponentami, které nejsou přímo pozorovatelné proměnné jak je tomu u regrese (Sebera, 2012).

4 Výsledky práce

4.1 Výběr proměnných

V prvním kroku bylo nutné ze všech vypočtených ukazatelů, které byly představeny v rámci teoretického přehledu této práce²², vybrat pouze ty nejvýznamnější z nich. K tomu bylo využito vlastního úsudku založeného na finančních teoriích, využívaného i v dřívějších studiích. Tímto postupem bylo vybráno následujících 14 ukazatelů napříč spektrem základních skupin finančních ukazatelů (viz Tab. 6).

Tab. 6 Přehled použitých proměnných při klasifikaci s odkazem na použitý vzorec

Celková zadluženost (2)	Rentabilita aktiv (8)
Koeficient samofinancování (3)	Rentabilita tržeb (6)
Míra zadluženosti (4)	Zisková marže (7)
Úrokové krytí (5)	Obrat aktiv (11)
Běžná likvidita (10)	Obrat zásob (12)
Pohotová likvidita (9)	Doba obratu pohledávek (13)
Čistý pracovní kapitál (1)	Doba obratu závazků (14)

S touto skupinou ukazatelů se bude dále pracovat v rámci výstavby modelu. V případě modelů s algoritmem podpůrných vektorů se využije pro další selekci proměnných tzv. gain ratio – proměnné se budou vybírat podle jejich informační hodnoty. U modelů na základě rozhodovacích stromů se už nevyužívá žádné dodatečné filtrace, neboť tato metoda sama o sobě slouží k volbě proměnných. Blížeji se těmto modelům bude věnovat Kapitola 4.4, která se zabývá vyhodnocení predikce a testování přesnosti jednotlivých modelů.

4.2 Základní statistické údaje

Pro všechny významné finanční ukazatele byly vypočteny základní statistické charakteristiky polohy. Pro lepší přehlednost byly tyto hodnoty rozděleny do čtyř následujících tabulek podle jednotlivých skupin finančních ukazatelů. V tabulkách je také rozlišeno, zda tyto hodnoty vznikly z dat od zbankrotovaných či od stále

²² Předem bylo nutné ze souboru uvažovaných proměnných vyřadit některé ze skupiny ukazatelů rentability. Jedná se například o ukazatel rentability vlastního kapitálu (ROE), který v sobě pracuje jak s hodnotou čistého zisku, tak zároveň i s výší vlastního kapitálu. Jedná se tedy o složky, které v sobě zahrnují výsledek hospodaření, který v důsledku způsobil, že obě tyto složky ukazatele ROE měla většina společností ze skupiny zbankrotovaných společností záporné. Matematický výpočet takového ukazatele by pak podával nesmyslné informace, a proto bylo nutné takového ukazatele ze souboru odstranit.

aktivních společností. První z těchto analyzovaných skupin ukazatelů jsou ukazatele zadluženosti, které v sobě zahrnují následující čtyři ukazatele, viz Tab. 7.

Tab. 7 Statistické charakteristiky pro ukazatele zadluženosti

Ukazatel	Skupina	Rok	Průměr	Min	1.kvartil	Medián	3.kvartil	Max
Celková zadluženost (%)	Aktivní společnosti	2011	65,77	8,29	52,94	66,88	79,63	186,39
		2012	64,48	7,11	50,40	64,90	79,88	185,65
		2013	63,14	6,41	48,79	63,64	78,85	167,62
	Zbankrotované společnosti	2011	94,28	62,61	85,71	93,14	98,44	142,57
		2012	114,32	57,82	90,78	97,45	106,93	409,20
		2013	182,67	59,97	102,37	138,58	193,02	916,98
Koeficient samofinancování (%)	Aktivní společnosti	2011	34,25	-86,39	20,39	33,12	47,06	91,71
		2012	35,52	-85,65	20,12	35,10	49,60	92,89
		2013	36,86	-67,62	21,15	36,36	51,21	93,59
	Zbankrotované společnosti	2011	5,73	-42,57	1,58	6,86	14,29	37,39
		2012	-0,10	-77,35	-3,39	2,55	9,22	42,18
		2013	-21,68	-93,67	-42,59	-18,42	1,81	40,03
Míra zadluženosti	Aktivní společnosti	2011	13,42	-67,90	1,08	1,96	3,80	7718,27
		2012	-2,49	-4995,46	0,97	1,76	3,71	161,39
		2013	1,56	-1797,62	0,90	1,69	3,48	329,64
	Zbankrotované společnosti	2011	18,29	-27,32	3,15	9,14	21,23	106,71
		2012	18,83	-60,34	-1,90	7,69	27,14	190,07
		2013	10,45	-20,50	-3,51	-2,07	0,19	255,96
Úrokové krytí	Aktivní společnosti	2011	31,17	-76,42	1,89	6,90	20,88	975,70
		2012	30,27	-69,09	1,69	6,97	22,75	933,64
		2013	39,82	-98,63	1,91	7,82	30,34	961,00
	Zbankrotované společnosti	2011	7,00	-14,20	-1,06	1,11	1,62	343,03
		2012	-1,32	-44,91	-5,80	-0,78	1,07	122,22
		2013	-26,15	-606,81	-21,12	-9,49	-3,98	251,84

Základním ukazatelem této skupiny je **celková zadluženost**. Z uvedených Tab. 7 vyplývá, že průměrné hodnoty aktivních podniků se pohybují těsně u horní obecně (bez ohledu na odvětví) doporučené hranice 60 %. Dále lze z výpočtů konstatovat, že 75 % ze sledovaných aktivních společností se nikdy nedostalo přes 80 % hodnotu celkového zadlužení. Navíc se dá u skupiny aktivních společností pozorovat, jak s postupem času vypočtené hodnoty vykazují pomalou sestupnou tendenci. Přesně opačný a navíc mnohem rychlejší vývoj je u hodnot druhé skupiny, tedy zbankrotovaných podniků. Průměrná hodnota celkového zadlužení v roce 2012 už významně přesáhla hodnotu 100 % (hodnota mediánu až o rok později), což ukazuje, že podniky mají vyšší hodnotu cizích zdrojů než je celková hodnota

aktiv v podniku²³. Velký rozdíl je možno vidět také v nejlepších a nejhorších hodnotách podniků mezi těmito dvěma skupinami – zajímavé je zejména srovnání maximálních hodnot v roce 2011, kdy měl podnik ze skupiny aktivních společností mnohem vyšší míru celkového zadlužení nežli podniky z druhé skupiny. Další zajímavostí je také zjištění, že ačkoliv se průměrná hodnota a medián souboru z aktivních společností neustále přibližuje, tak u zbankrotovaných podniků je tomu přesně naopak. Druhým ukazatelem této skupiny je **koeficient samofinancování**, jenž v sobě zrcadlí hodnoty celkové zadluženosti. Jelikož se jedná o doplněk k celkové zadluženosti, tak součty průměrných hodnot (stejně jako součty příslušných krajních hodnot i hodnot dolního a horního kvartilu) obou těchto ukazatelů by měly dávat 100 %.

Míra zadluženosti se většinou posuzuje z dlouhodobějšího hlediska, aby se zjistila tendence, zda se podíl cizích zdrojů zvyšuje či snižuje. Obecně lze u obou sledovaných skupin společností konstatovat, že se průměrná hodnota tohoto ukazatele v čase snižuje, přičemž u zbankrotovaných podniků (v roce 2012 u více jak 25 %, o rok později už u více jak 50 % podniků) se dostáváme až do záporných hodnot²⁴. Tuto skupinu ukazatelů uzavírá ukazatel **úrokového krytí**, který ukazuje kolikrát je zisk větší než úroky. Z Tab. 7 je patrné, že více jak tři čtvrtiny aktivních podniků by i při snížení jejich zisků bylo stále schopno udržet si stávající úroveň cizích zdrojů. U druhé skupiny společností jsou hodnoty tohoto ukazatele pro většinu podniků záporné, a to zejména v roce 2013, kdy více jak 75 % zbankrotovaných podniků mělo zápornou hodnotu výsledku hospodaření.

Tab. 8 Statistické charakteristiky pro ukazatele likvidity

Ukazatel	Skupina	Rok	Průměr	Min	1.kvartil	Medián	3.kvartil	Max
Běžná likvidita	Aktivní společnosti	2011	1,88	0,26	1,20	1,52	2,03	29,29
		2012	1,96	0,28	1,19	1,54	2,14	44,01
		2013	1,93	0,31	1,18	1,57	2,19	12,23
	Zbankrotované společnosti	2011	1,21	0,38	0,95	1,09	1,42	2,98
		2012	1,11	0,21	0,80	1,01	1,27	4,49
		2013	1,04	0,10	0,45	0,75	1,02	12,35
Pohotová likvidita	Aktivní společnosti	2011	1,23	0,11	0,73	0,98	1,40	13,38
		2012	1,30	0,16	0,73	1,01	1,46	28,98
		2013	1,31	0,10	0,76	1,05	1,50	11,87
	Zbankrotované společnosti	2011	0,72	0,09	0,50	0,67	0,95	1,54
		2012	0,65	0,03	0,38	0,59	0,86	1,51
		2013	0,66	0,05	0,27	0,41	0,68	9,06

²³ Účetní rovnováha aktiv a pasiv je u takovýchto podniků vyrovnána zápornou hodnotou vlastního kapitálu, resp. záporným výsledkem hospodaření.

²⁴ Což bychom mohli taktéž vysvětlit zápornou hodnotou vlastního kapitálu, resp. ztrátou.

Čistý pracovní kapitál	Aktivní společnosti	2011	42568	-627427	5270	15026	32469	1861677
		2012	49021	-1089955	5846	15758	33154	3730318
		2013	50801	-1581059	6098	16189	34791	5814132
	Zbankrotované společnosti	2011	343	-1666	-68	149	677	3700
		2012	-344	-9944	-322	5	319	2630
		2013	-1034	-11965	-1019	-434	-18	1753

Jak je vidět v Tab. 8, tak průměrné hodnoty **běžné likvidity** u aktivních společností se drží v obecně doporučeném intervalu 1,5–2,5, více jak 75 % společností z této skupiny by nemělo mít problém pokrýt krátkodobé závazky svými oběžnými aktivy. Zbankrotované společnosti mají hodnoty běžné likvidity značně nižší, více jak 75 % společností nedosáhne ani ke spodní hranici ideálních hodnot. Z čehož se dá usuzovat, že zbankrotované společnosti se častěji drží agresivnější strategie při svém podnikání. Ke stejné myšlence by nás dovedl i pohled na **pohotovou likviditu**, kde jsou obecně doporučené hodnoty u konzervativní strategie v intervalu od 1–1,5. I zde spadají průměrné hodnoty tohoto ukazatele u aktivních společností do doporučeného intervalu, navíc vykazují rostoucí tendenci. V rámci druhé skupiny podniků více jak 75 % společností stále nedosahuje ke spodní hranici doporučeného intervalu.

Poslední ukazatel této skupiny je jediným rozdílovým ukazatel mezi všemi finančními ukazateli v této analýze. Jedná se o **čistý pracovní kapitál**, na který lze pohlížet nejenom jako na část oběžných aktiv financovanou dlouhodobými zdroji, ale i jako na finanční „polštář“, který společnost může využít pro svoji činnost, kdyby byla nucena splatit všechny své krátkodobé závazky. Z výše jeho vypočtených hodnot je jasně patrné, že převážná většina aktivních společností (více jak 3/4) má jeho hodnotu kladnou a má tedy jakýsi finanční polštář pro své aktivity. Druhá skupina společností má naopak tuto hodnotu spíše zápornou, v posledním sledovaném roce už více jak 75 % zbankrotovaných společností nedosahuje ke kladné hodnotě tohoto ukazatele. Ukazatelé likvidity obecně mají silnou propojenost s ukazateli rentability (neboť vysoká míra likvidity se projevuje na úkor rentability), jejíž vypočtené statistické hodnoty shrnuje Tab. 9.

Tab. 9 Statistické charakteristiky pro ukazatele rentability

Ukazatel	Skupina	Rok	Průměr	Min	1.kvartil	Medián	3.kvartil	Max
ROA (%)	Aktivní společnosti	2011	4,63	-49,21	0,66	3,95	7,82	74,75
		2012	4,54	-51,40	0,52	4,18	8,26	61,88
		2013	4,72	-31,77	0,44	3,82	8,31	46,60
	Zbankrotované společnosti	2011	-5,08	-56,89	-6,21	-0,13	0,23	11,55
		2012	-21,63	-233,61	-20,21	-3,64	0,14	3,94
		2013	-58,68	-461,71	-72,67	-38,03	-14,33	73,44

Zisková marže (%)	Aktivní společnosti	2011	4,82	-91,93	1,57	4,66	8,87	46,17
		2012	4,94	-97,24	1,31	4,39	8,78	46,46
		2013	5,34	-64,60	1,45	4,62	9,18	71,00
	Zbankrotované společnosti	2011	-9,21	-122,38	-6,68	0,82	1,99	4,94
		2012	-43,13	-928,27	-33,12	-3,99	0,29	710,91
		2013	-1596,70	-74658,00	-132,03	-65,77	-23,96	527,47
Rentabilita tržeb (%)	Aktivní společnosti	2011	5,52	-62,00	2,16	5,07	9,10	46,19
		2012	5,48	-66,66	2,14	4,99	9,01	34,52
		2013	5,75	-39,68	2,15	5,17	9,24	36,06
	Zbankrotované společnosti	2011	-4,71	-113,00	-2,90	2,76	4,62	17,62
		2012	-30,34	-801,96	-23,96	-1,73	3,40	650,71
		2013	-1468,64	-68998,95	-117,36	-57,68	-18,09	517,89

Pro celou skupinu těchto ukazatelů platí jednoduché pravidlo, čím vyšší hodnota daného ukazatele tím lépe pro každý podnik. Prvním z této skupiny ukazatelů je **rentabilita celkového kapitálu** (ROA). Jak je vidět, tak průměrné hodnoty tohoto ukazatele u zbankrotovaných podniků jsou záporné, což je u této skupiny podniků zapříčiněno záporným výsledkem hospodaření. V prvních dvou letech sledovaného období více jak 50 % společností, v roce 2013 dokonce už více jak tři čtvrtiny společností vykazují ztrátu. Oproti tomu většina aktivních společností dokázala z investovaného kapitálu (resp. aktiv) vygenerovat zisk.

Hodnoty dalších dvou ukazatelů nám dávají velice podobné informace, neboť oba poměřují zisk a tržby firmy. Přičemž **zisková marže** zde byla počítána ze zisku po zdanění (EAT), kdežto **rentabilita tržeb** byla počítána ze zisku před zdaněním a úroky (EBIT)²⁵. Je proto logické, že průměrné hodnoty rentability tržeb (u aktivních společností, které dosahují kladného výsledku hospodaření) jsou vyšší – v průměru o 0,55 procentního bodu.

Oba dva tyto ukazatele říkají, kolik korun zisku připadá na jednu korunu tržeb. Jelikož i zde se pracuje ziskem, obdobně jako u předchozího ukazatele ROA, je proto na první pohled zřetelné jaké množství společností dosahovalo v daném roce zisku či ztráty. Díky tomu lze také na hodnotách pozorovat, jak se zbankrotovaným podnikům postupem času stále více a více prohlubovala ztráta. Oproti tomu u aktivních podniků jsou průměrné hodnoty ziskové marže i rentability tržeb na konci sledovaného období vyšší nežli na jeho začátku. Tab. 10 zachycuje získané hodnoty pro další skupinu ukazatelů.

²⁵ Při porovnávání společností z jiných zemí, resp. podnikajících v jiných podmínkách (např. jiné daňové zatížení) se doporučuje sledovat zejména variantu výpočtu z EBIT.

Tab. 10 Statistické charakteristiky pro ukazatele aktivity

Ukazatel	Skupina	Rok	Průměr	Min	1.kvartil	Medián	3.kvartil	Max
Obrat aktiv	Aktivní společnosti	2011	3,38	0,20	1,60	2,52	3,95	37,52
		2012	3,32	0,09	1,64	2,52	3,80	40,15
		2013	3,39	0,15	1,58	2,41	3,75	133,49
	Zbankrotované společnosti	2011	4,41	0,27	1,55	3,33	5,02	16,38
		2012	3,51	0,01	1,65	2,68	4,33	18,47
		2013	2,73	0,00	0,57	1,52	3,40	13,43
Obrat zásob	Aktivní společnosti	2011	9,34	0,26	3,61	5,61	8,90	705,24
		2012	10,49	0,33	3,83	5,75	9,21	505,00
		2013	10,74	0,25	3,80	5,86	9,74	397,17
	Zbankrotované společnosti	2011	5,11	0,27	1,96	3,16	4,84	51,03
		2012	4,31	0,01	1,60	2,75	5,08	25,36
		2013	15,37	0,00	1,00	2,57	7,45	330,04
Doba obratu pohledávek (dny)	Aktivní společnosti	2011	71,13	0,00	36,67	66,00	97,25	403,56
		2012	69,09	0,00	34,29	63,89	91,98	453,40
		2013	69,68	0,00	35,36	63,66	93,95	477,07
	Zbankrotované společnosti	2011	175,97	0,00	71,34	111,73	192,69	1489,02
		2012	272,76	0,00	60,62	142,57	231,72	5256,29
		2013	5802,56	0,00	52,73	151,82	401,17	278968,55
Doba obratu závazků (dny)	Aktivní společnosti	2011	53,32	0,00	25,28	46,86	75,55	498,46
		2012	49,07	0,00	23,68	42,93	69,21	200,53
		2013	48,82	0,00	21,23	43,03	68,23	228,92
	Zbankrotované společnosti	2011	131,83	0,00	59,06	97,94	151,36	938,44
		2012	232,88	0,00	76,17	114,01	161,78	4185,27
		2013	2611,99	0,00	87,16	230,94	554,47	110407,83

Nejkomplexnějším ukazatelem této skupiny je **obrat aktiv**, neboť v sobě zahrnuje všechna aktiva podniku. Je zajímavé pozorovat průměrné hodnoty tohoto ukazatele v rámci obou skupin podniků. Zejména v roce 2012 si byly tyto hodnoty velice blízké, ale jejich rozdílnost spatříme v časovém vývoji. Zatímco aktivní společnosti mají své průměrné hodnoty relativně stálé, tak u zbankrotovaných podniků zřetelně vidíme neustálý propad. Je obecně doporučováno, aby hodnota tohoto ukazatele byla vyšší jak jedna – což splňuje víc jak 75 % aktivních i zbankrotovaných společností (v roce 2013 už tedy jen více jak polovina zbankrotovaných společností).

Dalším ukazatelem je **obrat zásob**, jehož průměrné hodnoty u aktivních společností vykazují pozvolný růst, což znamená, že firmy stále častěji prodávají a znovu naskladňují další zásoby. Navíc maximální hodnoty v rámci této skupiny podniků neustále klesají, což znamená, že se společnosti zbavily přebytečných zásob, které jim zadržovaly finanční prostředky. Velice zajímavý je vývoj průměrných hodnot obratu zásob u druhé skupiny společností. Nejenom, že v prvních dvou le-

tech jsou tyto hodnoty výrazně nižší než u aktivních společností, ale v roce 2012 vidíme jistý pokles a v následujícím roce 2013 více jak trojnásobný nárůst, který je však způsoben značným rozprodáváním podnikových zásob – často až celkovému prodeji všech zásob, což je potvrzuje minimální hodnota i hodnota dolního kvartilu v tomto roce.

Další dva ukazatelé této skupiny nejsou vyjádřeny jako počet obrátů, ale jedná se o dobu obratu vyjádřenou ve dnech. Průměrné hodnoty **doby obratu pohledávek** stejně jako **doby obratu závazků** jsou několika násobně kratší u aktivních podniků nežli u podniků zbankrotovaných, u kterých se navíc tato doba v průběhu času neustále prodlužuje. Zajímavé jsou i minimální hodnoty obou těchto ukazatelů. Nulová hodnota nám totiž nabízí pohled, že v každé skupině existuje alespoň jeden podnik, který neeviduje žádné pohledávky ani závazky²⁶.

4.2.1 Základní statistické údaje nejlepších a nejhorších společností

Dále bylo využito metody prostého pořadí, jakožto jedné z možných metod pro hodnocení podniků, aby bylo možné zjistit pět nejlepších a pět nejhorších společností z každé skupiny tj. z aktivních i ze zbankrotovaných společností. Za možná kritéria této metody byla zvolena skupina pro nás významných ukazatelů rentability, tedy rentabilitu celkového vloženého kapitálu, rentabilitu tržeb a ziskovou marži. Skupina ukazatelů zadluženosti a likvidity by nebyla pro naše účely vhodná, neboť tyto ukazatelé mají nastaveny ideální hodnoty různě podle individuální strategie dané společnosti. Skupina ukazatelů aktivity by sice byla vhodná pro stanovení pořadí aktivních společností, avšak ve skupině zbankrotovaných společností by výsledky mohly být zkreslené zejména kvůli rozprodávání zásob některých společností. Jelikož bylo při vyhodnocování nejlepších a nejhorších společností využito pouze skupiny ukazatelů rentability, tak lze dané společnosti nazvat i jako nejvíce a nejméně ziskové společnosti z našeho datového souboru.

Tab. 11 Skupina nejziskovějších společností

Nejziskovější společnosti	
Z aktivních společností	Ze zbankrotovaných společností
1. FRISTAM Pupen KG (GmbH & Co.)	1. New PGS S.R.L.
2. Zardoya Otis, SA	2. HSP Group Oy
3. Mono Pumps Limited	3. F.I.M.S.A. S.R.L.
4. Buhler Sortex Limited	4. Bazzani Roversi Bazzani S.R.L.
5. Rotork Controls Limited	5. Omal SRL

²⁶ Tento fakt může být vysvětlen buď tím, že podnik využívá pouze hotovostních operací, nebo řešením platebního styku formou zápočtu vzájemných pohledávek a závazků (v případech, kdy je jeden subjekt jak dodavatelem, tak i odběratelem). Bohužel z povahy získaných dat není možné zjistit přesnou příčinu tohoto stavu.

Zcela nejziskovější společností z našeho datového souboru se stala původem německá společnost FRISTAM Pumpen KG (GmbH& Co.), která ovšem působí (stejně jako i zbylé čtyři nejziskovější aktivní společnosti) celosvětově – od Evropy, přes Asii, Austrálii až po USA (Fristam Pumpen, 2016). Všechny tyto TOP aktivní společnosti se vyznačují nejen širokým odbytištěm svých výrobků a služeb, ale i vysokou hodnotou celkových aktiv stejně jako i stabilního kladného výsledku hospodaření. Oproti tomu společnosti z druhé skupiny bychom mohli označit za menší společnosti působící zejména v dané zemi. Zajímavé také je, že čtyři z pěti nejziskovějších společností ze skupiny zbankrotovaných podniků jsou italské společnosti.

Tab. 12 Skupina nejméně ziskových společností

Nejméně ziskové společnosti	
Z aktivních společností	Ze zbankrotovaných společností
1. Luvata Italy S.R.L.	1. C. S.Costruzione Macchine Speciali S.R.L.
2. Moventas Gears Oy	2. Imeck S.R.L.
3. Terex Operations Italy SRL	3. Rizzio SPA
4. Ingersoll-Rand Italiana SPA	4. E.S.P. S.R.L.
5. OlivettiS.P.A.	5. Takoma Systems Oy

I v této skupině nejméně ziskových společností dominují italské společnosti. Přičemž ty ze skupiny aktivních mají stále vysoké hodnoty celkových aktiv (v řádech desítek až stovek milionů EUR) i celosvětová odbytiště, avšak minimálně v jednom ze sledovaných období nedosáhly zisku.

Nejméně ziskové společnosti ze skupiny zbankrotovaných jsou na základě hodnot celkových aktiv (zejména dlouhodobého majetku) obdobné jako i ty nejziskovější, avšak dosahují mnohonásobně větší ztráty než společnosti v Tab. 11.

Tab. 13 Statistické charakteristiky pro skupinu nejziskovějších společností

Ukazatel	Skupina spol.	Průměr	Min	1.kvartil	Medián	3.kvartil	Max
Celková zadluženost (%)	Aktivní	47,86	29,99	36,12	50,56	54,55	68,06
	Zbankrotované	85,09	60,13	80,41	90,78	95,73	98,40
Koeficient samofinancování (%)	Aktivní	52,14	31,94	45,45	49,44	63,88	70,01
	Zbankrotované	14,94	1,77	4,27	9,22	19,59	39,87
Míra zadluženosti	Aktivní	1,09	0,43	0,57	1,05	1,20	2,19
	Zbankrotované	19,74	1,51	4,12	12,43	24,29	56,33
Úrokové krytí	Aktivní	186,63	3,90	43,04	74,84	354,47	456,92
	Zbankrotované	41,55	-2,61	0,40	1,08	4,43	204,44
Běžná likvidita	Aktivní	2,47	1,13	1,31	2,95	3,29	3,69
	Zbankrotované	1,63	0,83	1,19	1,64	2,09	2,40

Pohotová likvidita	Aktivní	1,93	1,03	1,19	2,11	2,40	2,89
	Zbankrotované	0,94	0,44	0,79	0,85	1,14	1,50
Čistý pracovní kapitál	Aktivní	31432	21438	23693	29955	35567	46506
	Zbankrotované	561	-9	74	652	860	1228
ROA (%)	Aktivní	32,07	19,91	27,26	29,36	36,46	47,35
	Zbankrotované	0,30	-3,43	-0,50	0,17	1,22	4,01
Zisková marže (%)	Aktivní	30,61	20,56	27,21	31,07	33,06	41,17
	Zbankrotované	0,03	-5,60	-2,46	0,54	1,71	5,98
Rentabilita tržeb (%)	Aktivní	26,59	19,14	24,45	25,64	31,25	32,49
	Zbankrotované	2,71	-2,80	1,11	3,50	4,66	7,06
Obrat aktiv	Aktivní	2,30	1,67	2,10	2,20	2,68	2,82
	Zbankrotované	3,08	1,02	1,14	2,11	2,84	8,27
Obrat zásob	Aktivní	13,77	6,18	7,62	10,32	12,66	32,06
	Zbankrotované	3,19	1,24	1,85	2,41	3,73	6,71
Doba obratu pohledávek (dny)	Aktivní	55,65	10,30	32,91	57,87	81,58	95,61
	Zbankrotované	177,14	49,89	105,77	168,49	240,10	321,46
Doba obratu závazků (dny)	Aktivní	18,46	7,43	10,00	14,67	27,90	32,32
	Zbankrotované	117,93	49,01	66,25	101,89	155,81	216,70

Všechny hodnoty celkové zadluženosti nejlepších aktivních společností se pohybují v rozmezí 30 až 68 procent, tedy velice blízko obecně doporučeného intervalu 30–60 %. Hodnoty koeficientu samofinancování se tedy logicky musí pohybovat v rozmezí 32 až 70 procent. Při pohledu pouze na průměrné hodnoty těchto dvou ukazatelů, tak lze konstatovat, že společnosti financují svoje aktiva spíše z vlastních zdrojů. Na správné fungování těchto společností ukazují i hodnoty úrokového krytí – zisk těchto společností je totiž dostatečný nejen pro splácení dluhů, ale i pro stát a vlastníka (tj. v podobě daní a čistého zisku).

Z hodnot skupiny ukazatelů likvidity se dá tvrdit, že tato skupina nejlepších podniků nemá problémy s likviditou, více jak polovina z těchto společností má navíc hodnoty běžné a pohotové likvidity ještě vyšší než jsou horní hranice obecně doporučených intervalů. Zajímavé je, že tyto nadprůměrně vysoké hodnoty likvidity mají společnosti, které mají také vysoké hodnoty koeficientu samofinancování (např. společnost Mono Pumps Limited), což svědčí o jejich konzervativnější strategii.

Ze skupiny ukazatelů aktivity je patrné, že tato skupina podniků využívá efektivně svých aktiv a mají správně nastavené dodavatelsko-odběratelské vztahy. Není tedy divu, že dosahují rentability celkového kapitálu ve výši 20–47 %, rentability tržeb mezi 19–32 % a ziskové marže v rozpětí 20–41 %. Při pohledu na vypočtené hodnoty jednotlivých ukazatelů v rámci nejlepších ze skupiny zbankrotovaných společností vidíme, že se jedná o společnosti s mnohem vyšší celkovou zadlužeností a logicky tak mnohem nižší hodnotou koeficientu samofinancování. Výraznou

změnu lze pozorovat i u ostatních ukazatelů ze skupiny ukazatelů zadluženosti. Průměrná hodnota míry zadluženosti se zde zvýšila oproti hodnotě u aktivních společností více jak 18krát, naopak průměrná hodnota úrokového krytí u skupiny zbankrotovaných společností se snížila na zhruba čtvrtinu hodnoty u druhé skupiny společností – navíc se v rámci minimálních hodnot dostáváme i do záporných hodnot, což poukazuje na zápornou hodnotu zisku minimálně jedné společnosti z dané skupiny.

Podle vypočtených hodnot ukazatelů likvidity se dá usuzovat, že tato druhá skupina podniků je obecně mnohem méně likvidní a v hodnotách čistého pracovního kapitálu se v rámci minimálních hodnot dostáváme i do záporných čísel. V tomto souboru tedy existuje subjekt, který nedokáže uhradit veškeré své krátkodobé závazky pouze z prostředků ve formě oběžných aktiv.

Již zmiňovanou ztrátu některých z pěti nejziskovějších zbankrotovaných společností potvrzují i záporné hodnoty v rámci všech sledovaných ukazatelů rentability (min. hodnoty popř. i hodnoty dolního kvartilu). Další velkou rozdílnost mezi těmito dvěma skupinami společností spatřujeme v hodnotách doby obrátu pohledávek a závazků – u aktivních podniků se tyto hodnoty pohybovali v rámci několika dní až čtvrt roku, naopak u zbankrotovaných společností je toto rozpětí od jednoho až přes deset měsíců.

Na první pohled dosahují v rámci průměrných hodnot obrátu aktiv lepších výsledků zbankrotované společnosti oproti těm ze skupiny aktivních, avšak těchto „lepších“ hodnot dosáhly zejména díky velmi vysoké hodnotě obrátu aktiv společnosti Takoma Systems Oy v roce 2013, kdy společnost rapidně redukovala výši svého dlouhodobého majetku, což se projevilo právě v extrémně vysoké hodnotě obrátu aktiv. V Tab. 14 se už přesune pozornost k základním statistickým charakteristikám vypočítaných pro skupinu pěti nejméně ziskových společností z obou sledovaných skupin.

Tab. 14 Statistické charakteristiky pro skupinu nejméně ziskových společností

Ukazatel	Skupina spol.	Průměr	Min	1.kvartil	Medián	3.kvartil	Max
Celková zadluženost (%)	Aktivní	80,48	43,42	65,54	87,46	96,19	109,80
	Zbankrotované	170,63	80,17	134,03	165,39	218,39	255,20
Koeficient samofinancování (%)	Aktivní	19,52	-9,80	3,81	12,54	34,46	56,58
	Zbankrotované	-0,43	-22,29	-3,41	-0,12	3,84	19,83
Míra zadluženosti	Aktivní	522,74	-6,86	0,93	5,38	9,78	2604,50
	Zbankrotované	7,65	-10,39	-4,08	-1,18	25,76	28,15
Úrokové krytí	Aktivní	46,35	-20,41	-9,15	-6,84	-2,16	270,29
	Zbankrotované	-42,38	-210,62	-29,25	-11,80	-5,93	45,72
Běžná likvidita	Aktivní	1,61	0,93	1,13	1,24	1,84	2,88
	Zbankrotované	1,07	0,45	0,53	0,80	1,05	2,52

Pohotová likvidita	Aktivní	1,19	0,68	0,84	0,97	1,41	2,06
	Zbankrotované	0,46	0,21	0,24	0,37	0,56	0,95
Čistý pracovní kapitál	Aktivní	20577	-3617	10969	20434	23504	51593
	Zbankrotované	-794	-3406	-1071	-221	-65	791
ROA (%)	Aktivní	-16,20	-30,76	-23,27	-15,95	-9,32	-1,69
	Zbankrotované	-61,01	-121,86	-76,39	-58,01	-34,50	-14,29
Zisková marže (%)	Aktivní	-34,57	-80,66	-39,33	-26,67	-24,00	-2,18
	Zbankrotované	-288,17	-827,21	-273,30	-171,97	-141,47	-26,89
Rentabilita tržeb (%)	Aktivní	-21,46	-49,27	-36,15	-14,88	-10,48	3,51
	Zbankrotované	-259,95	-759,36	-259,77	-140,32	-115,56	-24,73
Obrat aktiv	Aktivní	2,24	0,39	0,62	2,02	2,91	5,26
	Zbankrotované	3,60	0,28	0,99	1,77	4,50	10,47
Obrat zásob	Aktivní	6,65	3,30	3,47	5,15	8,60	12,73
	Zbankrotované	11,87	0,49	0,92	1,33	1,84	54,78
Doba obratu Pohledávek (dny)	Aktivní	58,67	0,34	53,27	64,17	79,97	95,62
	Zbankrotované	219,43	24,74	55,85	183,54	321,36	511,63
Doba obratu závazků (dny)	Aktivní	71,43	38,56	54,98	64,80	83,19	115,65
	Zbankrotované	608,16	37,45	363,78	505,29	813,08	1321,20

Zajímavý pohled se dá získat, pokud se porovnájí hodnoty celkové zadluženosti nejhorsích z aktivních společností spolu s nejlepšími podniky v rámci skupiny zbankrotovaných společností. Ačkoliv si jsou průměrné hodnoty tohoto ukazatele velice blízké, tak hodnoty v rámci aktivních společností mají mnohem širší rozpětí (rozdíl minimálních a maximálních hodnot je zde o více jak 66 jednotek, kdežto u skupiny nejziskovějších zbankrotovaných podniků je toto rozpětí skoro o polovinu nižší).

Při pohledu na výše vypočtené hodnoty koeficientu samofinancování je vidět, že minimální hodnoty jsou u obou skupin v záporných hodnotách, avšak oproti nejméně ziskovým z aktivních společností má většina ze zbankrotovaných společností hodnotu tohoto ukazatele zápornou, díky čemuž jsou i průměrné hodnoty koeficientu samofinancování u této skupiny také záporné, kdežto u aktivních společností jsou stále kladné.

Ačkoliv už v předešlé Tab. 13 (hodnoty pro nejziskovější společnosti) byly viditelné rozdíly mezi aktivními a zbankrotovanými společnostmi v rámci ukazatele míry zadluženosti (rozdíl v rámci průměrných hodnot zde byl skoro o 19 jednotek), tak v tomto případě – díky hodnotám společnosti Moventas Gears Oy, která v roce 2011 měla hodnoty finančních zdrojů poskytnutých od vlastníků pouze v rámci desítek tisíc EUR – jsou rozdíly nepřehlédnutelné. V následujících letech se už hodnoty finančních zdrojů v rámci zmíněné společnosti několika násobně navýšily, což ve výsledku způsobilo, že průměrné hodnoty ukazatele míry zadluženosti těchto nejméně ziskových zbankrotovaných společností se vyšplhaly na hod-

notu 522,74²⁷ – rozdíl mezi průměrnými hodnotami tohoto ukazatele v rámci obou sledovaných skupin činí více jak 515 jednotek.

Další znak jistých problémů nejméně ziskových společností lze vidět i v rámci hodnot posledního ze skupiny ukazatelů zadluženosti – úrokového krytí. V obou skupinách podniků se dají nalézt záporné hodnoty tohoto ukazatele. Avšak obdobně jako u koeficientu samofinancování dosahují průměrné hodnoty do záporných hodnot pouze u skupiny zbankrotovaných společností. Zajímavé je, že kladnou hodnotu úrokového krytí získala skupina aktivních společností jenom díky společnosti Ingersoll-Rand Italiana SPA, která jediná dosahuje dlouhodobě vysokých hodnot tohoto ukazatele. V rámci druhé skupiny zbankrotovaných společností se také najde pouze jedna společnost (E.S.P. S.R.L.), která dosahuje kladných výsledků v rámci tohoto ukazatele, avšak v součtu převáží výše záporných hodnot úrokového krytí, což symbolizuje právě záporná průměrná hodnota.

I v rámci skupiny ukazatelů likvidity lze pozorovat logický pokles v jednotlivých hodnotách. Je však zajímavé, že hodnoty běžné likvidity nejméně ziskových aktivních společností se velice blíží hodnotám nejziskovějších společností v rámci skupiny těch zbankrotovaných – průměrné hodnoty se zde liší o pouhé dvě setiny hodnoty. Při zkoumání jednotlivých ukazatelů likvidity z hlediska doporučovaných hodnot bylo zjištěno, že skupina aktivních společností se těmito hodnotám alespoň blíží (či je přímo splňuje) naopak zjištěné průměrné hodnoty ze zbankrotovaných společností nedosahují ani z poloviny k obecně doporučovaným hodnotám těchto ukazatelů.

Na základě hodnot další skupiny ukazatelů rentability lze konstatovat, že pouze jedna společnost v rámci každé ze sledovaných skupin dosáhla v rámci sledovaného období zisku. Na zhoršení finanční situace podniku poukazují i hodnoty doby obratu pohledávek a zejména doby obratu závazků, právě zde se zejména skupině zbankrotovaných společností prodlužuje doba úhrady vlastních závazků – maximální hodnota tohoto ukazatele zde činí více jak 1321 dní, tedy více jak 44 měsíců. Tento vysoký nárůst doby obratu závazků je způsoben nejenom poklesem tržeb, ale i rostoucí hodnotou závazků.

Při pohledu pouze na průměrné hodnoty zbylých dvou ukazatelů aktivity vyjádřených ve formě počtu obrátek, by se na první pohled mohlo zdát, že zbankrotované společnosti zde dosahují v průměru lepších výsledků než skupina aktivních podniků, avšak tato hodnota by se dala označit jako falešně pozitivní díky velkému rozprodávání zásob zejména v roce 2013, na což poukazují zejména maximální hodnoty obratu zásob, které zde jsou ještě vyšší než u nejziskovějších společností.

²⁷ Tento výkyv v hodnotách vznikl zejména ve složce ostatních vlastnických fondů, jež byla v rámci společnosti Moventas Gears Oy pro rok 2011 v záporných hodnotách. Další rok už byla tato složka pasiv nejenom kladná, ale i navýšená o více jak patnáctinásobek původní hodnoty.

4.3 Shluková analýza

Jak již bylo v práci řečeno, tak samotné shlukové analýze předchází metoda hlavních komponent, aby se tak dosáhlo redukce rozměrného souboru dat. Pomocí této metody vzniklo celkem 14 hlavních komponent (PC), které jsou zaznamenány do následujících třech tabulek. Pro samotnou shlukovou analýzu bude využito pouze prvních několik komponent, které dohromady popisují více než 90 % rozptylu.

Tab. 15 Podíl komponent na variabilitě souboru 2013

	PC1	PC2	PC3	PC4	PC5	PC6	PC7
Směrodatná odchylka	2,0163	1,3914	1,2611	1,10140	1,0089	0,98624	0,96604
Podíl rozptylu	0,2904	0,1383	0,1136	0,08665	0,0727	0,06948	0,06666
Kumulativní podíl	0,2904	0,4287	0,5423	0,62893	0,7016	0,77110	0,83776
	PC8	PC9	PC10	PC11	PC12	PC13	PC14
Směrodatná odchylka	0,9158	0,80293	0,55237	0,50629	0,33756	0,33533	0,01473
Podíl rozptylu	0,0599	0,04605	0,02179	0,01831	0,00814	0,00803	0,00002
Kumulativní podíl	0,8977	0,94371	0,96550	0,98381	0,99195	0,9998	1,00000

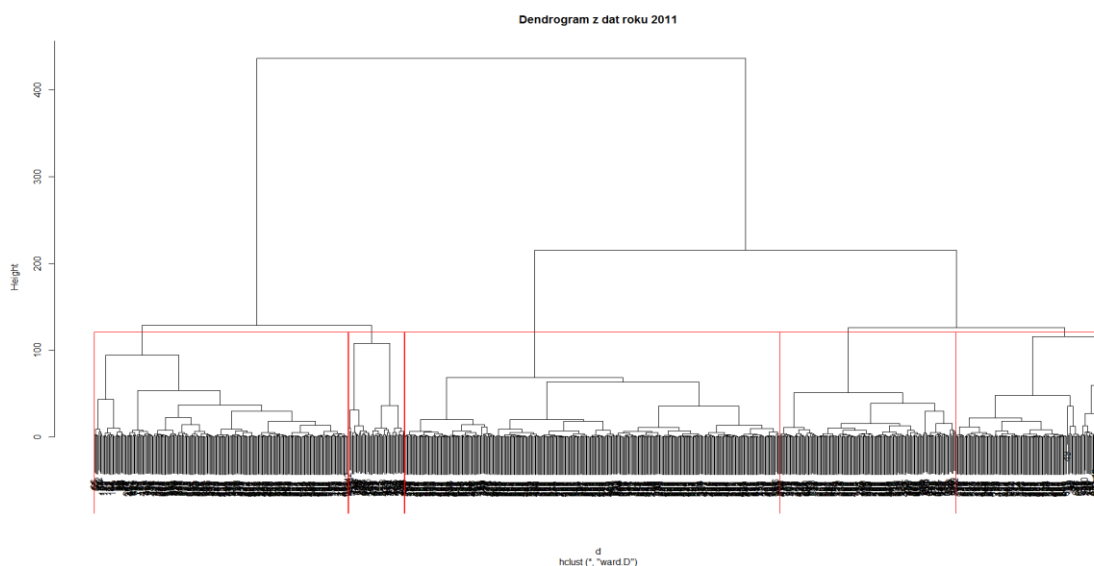
Tab. 16 Podíl komponent na variabilitě souboru 2012

	PC1	PC2	PC3	PC4	PC5	PC6	PC7
Směrodatná odchylka	1,7893	1,5069	1,2817	1,2232	1,0550	1,01768	0,94859
Podíl rozptylu	0,2287	0,1622	0,1173	0,1069	0,0795	0,07398	0,06427
Kumulativní podíl	0,2287	0,3909	0,5082	0,6151	0,6946	0,76859	0,83286
	PC8	PC9	PC10	PC11	PC12	PC13	PC14
Směrodatná odchylka	0,94057	0,89275	0,7010	0,23647	0,22181	0,21673	0,12142
Podíl rozptylu	0,06319	0,05693	0,0351	0,00399	0,00351	0,00336	0,00105
Kumulativní podíl	0,89605	0,95298	0,9881	0,99559	0,99559	0,99895	1,00000

Tab. 17 Podíl komponent na variabilitě souboru 2011

	PC1	PC2	PC3	PC4	PC5	PC6	PC7
Směrodatná odchylka	2,0110	1,6906	1,2571	1,04088	1,0068	0,96881	0,93934
Podíl rozptylu	0,2889	0,2041	0,1129	0,07739	0,0724	0,06704	0,06303
Kumulativní podíl	0,2889	0,4930	0,6059	0,68328	0,7557	0,82272	0,88574
	PC8	PC9	PC10	PC11	PC12	PC13	PC14
Směrodatná odchylka	0,92659	0,65708	0,48947	0,26164	0,02938	0,01925	0,002682
Podíl rozptylu	0,06133	0,03084	0,01711	0,00489	0,00006	0,00003	0,000000
Kumulativní podíl	0,94707	0,97791	0,99502	0,99991	0,99997	1,00000	1,000000


Při pohledu na jednotlivé hodnoty těchto 14 komponent lze konstatovat, že do shlukové analýzy bude ve všech třech případech (letech) vstupovat prvních osm hlavních komponent. Pomocí Wardovy metody byla následně provedena samotná shluková metoda. Jelikož se jedná o hierarchický typ shlukování, lze výsledky analýzy zaznamenat pomocí dendrogramů.



Obr. 12 Celý dendrogram pro rok 2011

Na Obr. 12 je zaznamenán výsledný dendrogram všech 953 společností z našeho datového souboru. Na něm je vidět, že zhruba ve výšce 120 bodů se vytvořilo celkem pět shluků. Tento „celkový“ pohled na tato data bohužel neumožňuje přesně určit společnosti a jejich rozmístění v rámci jednotlivých pěti shluků. Proto budou v dalším kroku představeny pouze části tohoto dendrogramu, které umožní lepší pohled na jednotlivé společnosti mezi kterými je větší rozdíl.


Dendrogram z dat roku 2011



Obr. 13 Dendrogram na základě dat z pravého konce pro rok 2011

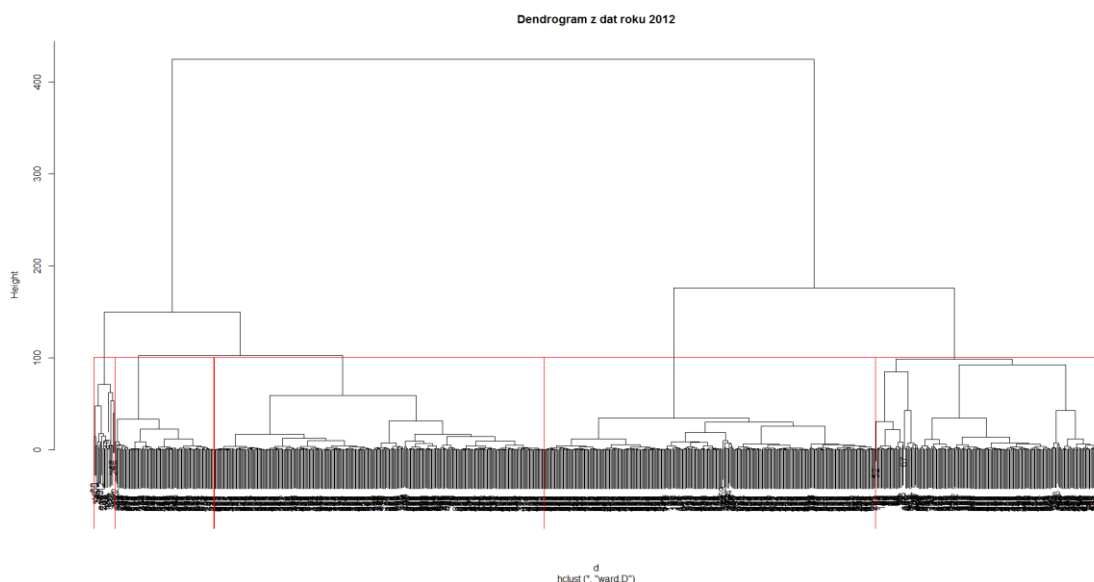
Největší část společností ze skupiny těch, které v roce 2014 dospěly k bankrotu (označené jako B), se v rámci dendrogramu z roku 2011 objevují nejvíce pospolu v jeho pravém konci, tedy v pátém shluku. Bankrotní společnosti jako Tecnoair S.R.L., Deparia Engineering S.R.L., Bazzani Roversi Bazzani S.R.L., Gema Macchine Automatiche SRL, Apiel S.R.L., Stemac S.R.L. atd. na Obr. 13 nespojuje jen právní forma, ale zejména hodnoty celkové zadluženosti (pohybující se v intervalu od 80 do 99 %) a běžné i pohotovové likvidity (u obou jsou hodnoty hluboko pod obecně doporučovanými intervaly). Dále pak je mezi těmito společnostmi vidět podobnost i v rámci hodnot rentability aktiv či doby obratu pohledávek. Velkou podobnost s těmito jmenovanými bankrotními společnostmi mají však i některé ze skupiny stále aktivních společností. Jedná se například o společnost Ansaldo Nucleare S.P.A. či Sulzer Pompes France, které mají obdobně vysoké hodnoty celkové zadluženosti i stejně nízkou likviditu.

Na zcela opačné straně (prvním shluku) dendrogramu, který zaznamenává Obr. 14, jsou už pouze jen společnosti ze skupiny těch aktivních. Tyto společnosti se oproti výše jmenovaným bankrotním společnostem liší zejména v ukazatelích zadluženosti. Průměrné hodnoty celkové zadluženosti zde klesly skoro na polovinu, logicky se proto zvedají i hodnoty koeficientu samofinancování. Společným pojítkem těchto společností je i míra zadluženosti, která se oproti bankrotním podnikům značně ustálila.



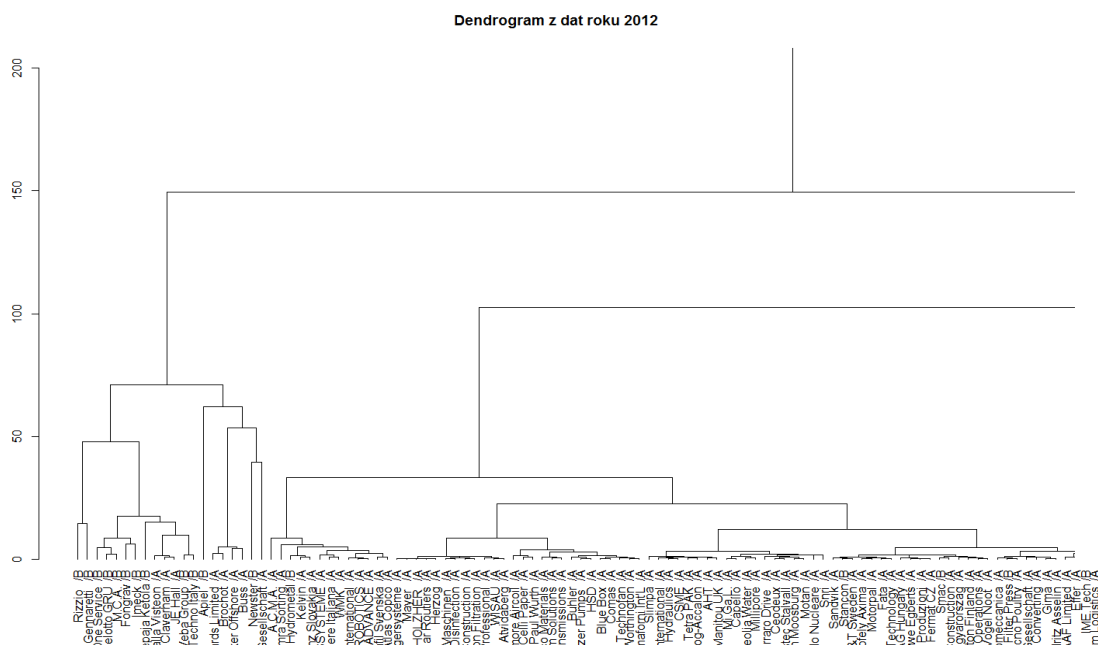
Obr. 14 Dendrogram na základě dat z levého konce pro rok 2011

Následující rok, tedy rok 2012, zobrazuje dendrogram na Obr. 15. I zde bylo nutné využít přiblíženého pohledu, aby bylo možné přesněji identifikovat polohu bankrotních společností v rámci jednotlivých pěti shluků.



Obr. 15 Celý dendrogram pro rok 2012

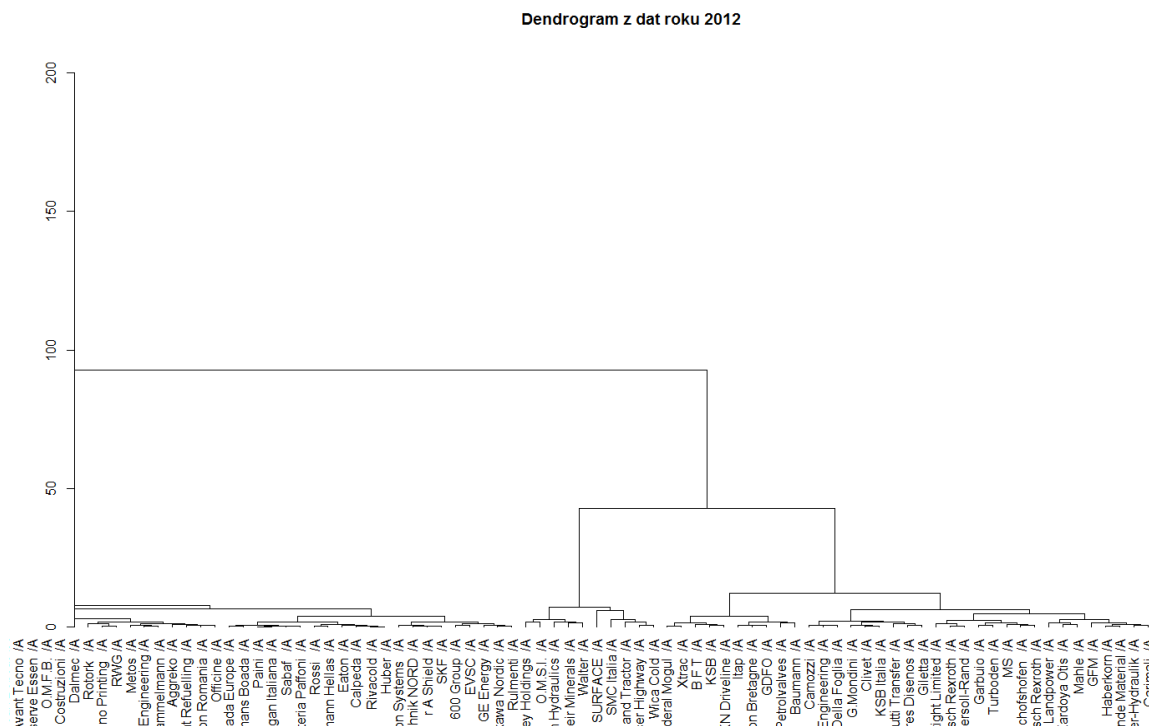
V roce 2012 lze nalézt většinu ze skupiny bankrotních společností v rámci prvního shluku, proto Obr. 16 zobrazuje výřez levého konce tohoto shluku, kde už lze jasně rozeznat názvy jednotlivých společností.




Obr. 16 Dendrogram na základě dat z levého konce pro rok 2012

Většina ze zbankrotovaných společností vyobrazených na Obr. 16 je k nalezení v jeho levé části. Stejně jako tomu bylo v předchozím roce 2011, tak i zde se tato skupina společností vyznačuje velmi vysokou hodnotou celkové zadluženosti. Navíc díky prohlubující se ztrátě mají všechny bankrotní společnosti zápornou hodnotu ROA a kromě jediné společnosti (Newster S.R.L.) mají všechny také záporné hodnoty ziskové marže i rentability tržeb. Aktivní společnosti, které jsou taktéž zobrazeny na stejném výřezu, byly takto shlukovány zejména díky výši svého koeficientu samofinancování (tedy i díky hodnotám celkové zadluženosti) či podle podobných hodnot ukazatele míry zadluženosti.

Všechny společnosti na Obr. 17 – jedná se zde výhradně o aktivní společnosti pocházející z pravého konce dendrogramu (část pátého shluku) – jsou taktéž spojovány podle svých obdobných hodnot koeficientu samofinancování (tím tedy i celkové zadluženosti), míry zadluženosti i úrokového krytí. Rozdíl mezi společnostmi nacházejícími se v pravé a levé části dendrogramu z roku 2012 můžeme spatřovat v kromě již zmíněných hodnot skupiny ukazatelů zadluženosti také v hodnotách doby obratu závazků. Společnostem z Obr. 17 nepřekročí hodnoty tohoto ukazatele dobu tří měsíců, kdežto společnosti vyznačené na Obr. 16 mají dobu obratu pohledávek v řádech několika měsíců až dokonce celého roku.




Poslední skupina obrázků zaznamenává shlukovou analýzu v roce 2013. Na Obr. 18 je zaznačených pět vzniklých shluků z tohoto roku. Stejně jako v předchozích případech i zde je nutno podívat se na výřezy z tohoto „celkového“ dendrogramu, aby bylo možné zjistit polohu bankrotních společností.



V roce 2013 lze bankrotní společnosti nalézt ve střední části diagramu. Proto bylo nutné udělat výřez ze čtvrtého shluku (viz Obr. 19), kde už se dají rozeznat názvy celkem 35 bankrotních společností. Oproti minulému roku 2012 jsou zde bankrotní společnosti shlukovány na úplně nejnižších hladinách, což dokazuje, jak si jsou v tomto roce tyto společnosti podobné. Dále lze tvrdit, že s blížícím se bankrotem se stále více společností shlukovalo do homogennějších skupin.

Dendrogram z dat roku 2013




Obr. 19 Dendrogram na základě dat ze středu diagramu pro rok 2013

Typickým znakem pro bankrotní společnosti z Obr. 19 je zejména jejich záporná hodnota ziskové marže a rentability tržeb způsobená dosaženým záporným výsledkem hospodaření. Ztráta těchto společností se taktéž silně projevila na rentabilitě aktiv či na koeficientu samofinancování – i zde tato skupina podniků dosahuje záporných hodnot obou těchto ukazatelů. V souboru společností na tomto obrázku se nacházejí i společnosti, které vykazují podobné signály, avšak v roce 2014 nedospěly k bankrotu. Například společnost Aker Offshore Partner Limited lze nalézt v každém ze tří sledovaných období poblíž skupiny bankrotních podniků.


Pro zjištění odlišností bankrotních společností od těch stále fungujících bylo nutné se zaměřit i na hodnoty jednotlivých ukazatelů společností ležících na obou krajích dendrogramu z roku 2013. Aktivní skupiny z obou stran dendrogramu se vyznačují obdobnými hodnotami zejména v ukazatelích doby obrátu pohledávek, doby obrátu závazků a pohotovostní likvidity. Rozdíly, které způsobily, že se tyto společnosti ocitly na krajích „celkového“ dendrogramu způsobily zejména rozdílné hodnoty zejména v koeficientu samofinancování (potažmo tedy i celkové zadluženosti). Skupina společností z Obr. 20 (konec pátého shluku) má tyto hodnoty v průměru kolem 30 %, naopak skupina z Obr. 19 (začátek prvního shluku) dosahuje v průměru hodnot téměř dvojnásobných.

Dendrogram z dat roku 2013



Obr. 20 Dendrogram na základě dat z pravého konce pro rok 2013

Dendrogram z dat roku 2013



Obr. 21 Dendrogram na základě dat z levého konce pro rok 2013

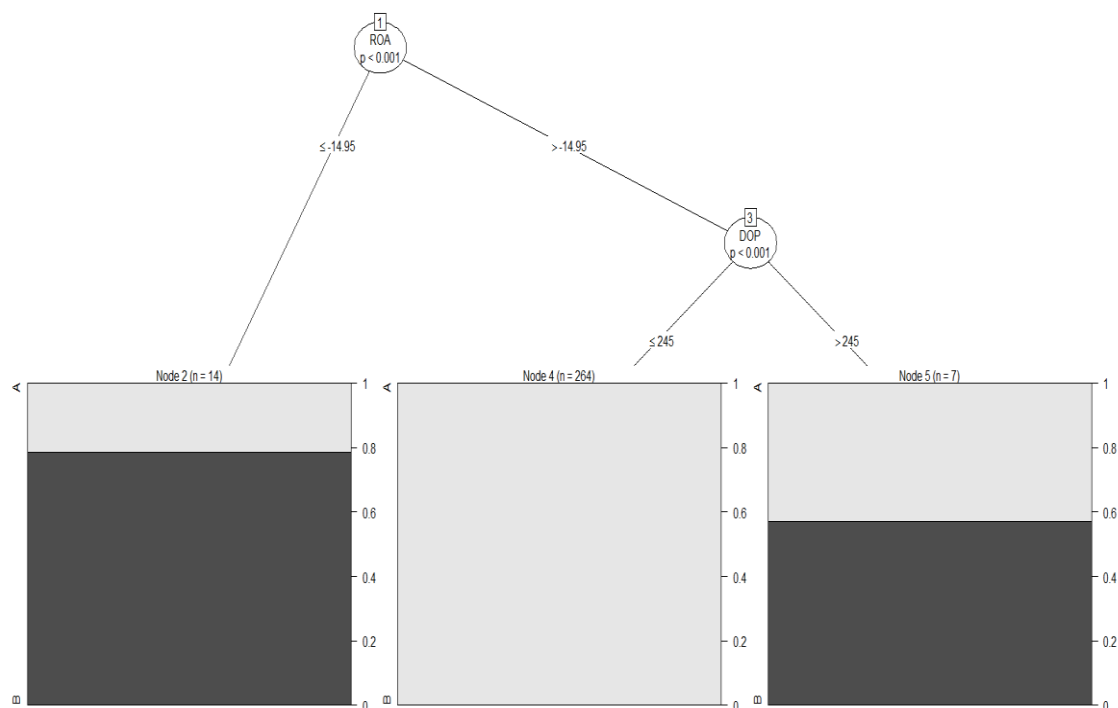
4.4 Vyhodnocení predikce, testování přesnosti modelu

V této kapitole je věnována pozornost hodnocení přesnosti klasifikace pomocí tří modelů – přesněji jde o modely vytvořené pomocí rozhodovacích stromů a modely s algoritmem podpůrných vektorů s odlišným typem jádra. Toto hodnocení bude

probíhat zejména pomocí chyb I. (15) a II. typu (16) a také pomocí výsledku výpočtu oblasti pod ROC křivkou (dále už jen jako AUC).

4.4.1 Výsledky pro rok 2013

Nejprve budou představeny výsledky DT modelu. Na Obr. 22 je vidět, jak tento model rozdělil celkem 285 společností podle daných proměnných vyhrazených pro trénování (učení) tohoto modelu.



Obr. 22 Klasifikace pomocí DT pro rok 2013

Na tomto stromu je vidět, že v rámci modelu zde byly využity celkem dvě proměnné. Jedná se o ROA, tedy rentabilitu celkového kapitálu (člen skupiny ukazatelů rentability), a DOP, coby ukazatele doby obratu pohledávek (člen skupiny ukazatelů aktivity). Pomocí klasifikace dle těchto dvou proměnných tak vznikly tři obdélníky do různé výšky vyplněné tmavou resp. i světlou barvou. Tento barevný podíl nám vlastně graficky zobrazuje podíl aktivních (A) a zbankrotovaných (B) společností v datovém souboru.

Na jednotlivých větvích rozhodovacího stromu lze vidět i přesné hodnoty proměnných, které slouží pro klasifikaci. V rámci grafu nalevo leží společnosti, které mají hodnoty ROA nižší nebo rovné hodnotě $-14,95$ %. Díky výplni obdélníku nalevo je patrné, že více jak 20 % z těchto společností je aktivních a zbylých necelých 80 % společností je ze skupiny zbankrotovaných společností. Nad příslušným obdélníkem vidíme i hodnotu $n=14$, což udává počet společností, jež byly ohraničeny tímto klasifikačním pravidlem.

Při postupu po větvi, kde jsou hodnoty ukazatele ROA větší jak číslo -14,95 %, lze dospět k dalšímu uzlu, tedy ukazateli doby obratu pohledávek, který rozděluje data dále na společnosti aktivní či zbankrotované podle hodnoty 245 dní. Obdélník vpravo představuje společnosti s ROA větší jak -14,95 % a dále s hodnotou doby obratu pohledávek větší jak 245 dní. Tímto klasifikačním pravidlem bylo ohraničeno celkem sedm společností, přičemž přes 60 % společností z nich je aktivních. Zbylých 264 společností, které jsou k nalezení v rámci prostředního obdélníku, se vyznačují hodnotami ROA -14,95 %, ale hodnoty doby obratu pohledávek mají kratší nebo rovnu číslu 245 dní. Na základě těchto výsledků lze konstatovat, že proces klasifikace společností na aktivní a zbankrotované zde není úplně dokonalý.

Dalším krokem je samotné testování tohoto modelu. Pro lepší přehlednost byly výsledky testování včetně jednotlivých vypočítaných měr hodnocení úspěšnosti klasifikace pomocí DT zaznamenány do následujících tří tabulek.

Tab. 18 Kontingenční tabulka pro DT model – absolutní hodnoty pro rok 2013

Predikovaná skupina	Skutečná skupina	
	A	B
	A	353
B	9	18

Z hodnot Tab. 18 je vidět, že tento model dokázal správně klasifikovat 353 aktivních společností (A) a také 18 bankrotních společností (B). Bohužel se v rámci tohoto modelu vyskytlo i 12 společností, které model zařadil do nesprávné klasifikační skupiny. V Tab. 19 je možno vidět tytéž výsledky klasifikace těchto 383 společností, avšak v relativním vyjádření.

Tab. 19 Kontingenční tabulka pro DT model – relativní vyjádření pro rok 2013

Predikovaná skupina	Skutečná skupina	
	A	B
	A	0,92
B	0,02	0,05

Model vytvořený pomocí rozhodovacích stromů správně klasifikoval společnosti v 97 % případů. Pro celkové hodnocení je však zapotřebí zahrnout i další informace obsažené v Tab. 20.

Tab. 20 Míry hodnocení úspěšnosti klasifikace DT model pro rok 2013

Celková správnost	0,97
Senzitivita	0,98
Specifická	0,86
Chyba I. typu	0,02
Chyba II. typu	0,14
AUC	0,92

Jak už bylo zmíněno výše, tak celková správnost tohoto modelu dosahuje v prvním roce před bankrotem 97 %. Jinak řečeno celková chybovost tohoto modelu dosahuje tří procent. O správnosti celkového modelu hovoří i hodnota AUC, které spadá do intervalu pro dobrou klasifikační schopnosti. V rámci predikční schopnosti bankrotu se pozornost zaměřuje zejména na chybovost klasifikace – zde tedy chyby I. a II. typu. V období jednoho roku před bankrotem dané skupiny společností, tento model chybně označil 14 % z bankrotních společností jako aktivních. Obdobně tento model nesprávně zařadil dvě procenta z aktivních společností do skupiny zbankrotovaných.

Pozornost se teď přesune k výsledkům modelů konstruovaných za pomoci algoritmu podpůrných vektorů. V roce 2013 do těchto modelů vstupuje na základě gain ratio těchto 5 proměnných: koeficient samofinancování, zisková marže, rentabilita tržeb, míra zadlužení a celková zadluženost. Nejprve bude představena predikční schopnost modelu, kde bylo využito tzv. RBF ANOVA jádra.

Tab. 21 Kontingenční tabulka pro SVM (RBF ANOVA) model – absolutní hodnoty pro rok 2013

Predikovaná skupina	Skutečná skupina		
		A	B
	A	358	2
B	4	19	

V Tab. 21 je možno vidět, že za pomocí takto zvoleného modelu bylo správně klasifikováno 358 aktivních a také 19 bankrotních společností. Celkem v šesti případech však tento model v rámci správné klasifikace neuspěl. Podíl těchto správných a nesprávných klasifikací na celém souboru testovacích dat pak zaznamenává Tab. 22.

Tab. 22 Kontingenční tabulka pro SVM (RBF ANOVA) model – relativní vyjádření pro rok 2013

Predikovaná skupina	Skutečná skupina		
		A	B
	A	0,93	0,01
B	0,01	0,05	

Na základě kontingenční tabulky (viz Tab. 22) lze konstatovat, že celkově model nesprávně řadil dvě procenta společností. Při klasifikaci ostatních 98 % společností model správně zařadil danou společnost do příslušné třídy. O správnosti tohoto modelu svědčí i vypočtené hodnoty z Tab. 23. Dle hodnoty AUC se dá hovořit o modelu, který dosáhl perfektní klasifikační schopnosti (což potvrzují i samotné hodnoty senzitivity a specificity). I pohled na zjištěné hodnoty chyb obou typů je velice uspokojivý – zejména pak fakt, že model označil jen 10 % z bankrotních společností chybně jako aktivní společnost.

Tab. 23 Míry hodnocení úspěšnosti klasifikace SVM (RBF ANOVA) model pro rok 2013

Celková správnost	0,98
Senzitivita	0,99
Specificita	0,90
Chyba I. typu	0,01
Chyba II. typu	0,10
AUC	0,97

Poslední model, kterému se budeme věnovat, byl stejně jako ten předchozí vytvořen prostřednictvím metody podpůrných vektorů, avšak zde bylo využito jiného jádra. Pro tento model bylo zvoleno polynomické jádro druhého stupně. V Tab. 24 jsou obsaženy výsledky v oblasti klasifikace pomocí SVM s tímto typem jádra.

Tab. 24 Kontingenční tabulka pro SVM (polynom) model – absolutní hodnoty pro rok 2013

Skutečná skupina	Predikovaná skupina	
	A	B
	A	357
B	5	16

Dané nastavení tohoto modelu umožnilo správně klasifikovat celkem 357 aktivních a dalších 16 bankrotních společností z celkového počtu 383 společností vyhrazených pro testování. Jinak řečeno model při testování správně zařadil celých 93 % aktivních a další 4 % bankrotních společností z celého souboru dat vyhrazeného pro testování (viz Tab. 25).

Tab. 25 Kontingenční tabulka pro SVM (polynom) model – relativní vyjádření pro rok 2013

Skutečná skupina	Predikovaná skupina	
	A	B
	A	0,93
B	0,01	0,04

Ze zjištěných hodnot správné a chybné klasifikace tohoto modelu v roce 2013 lze tvrdit, že celková chybovost zde dosahuje hodnoty tří procent. Z Tab. 26 se dá vy-

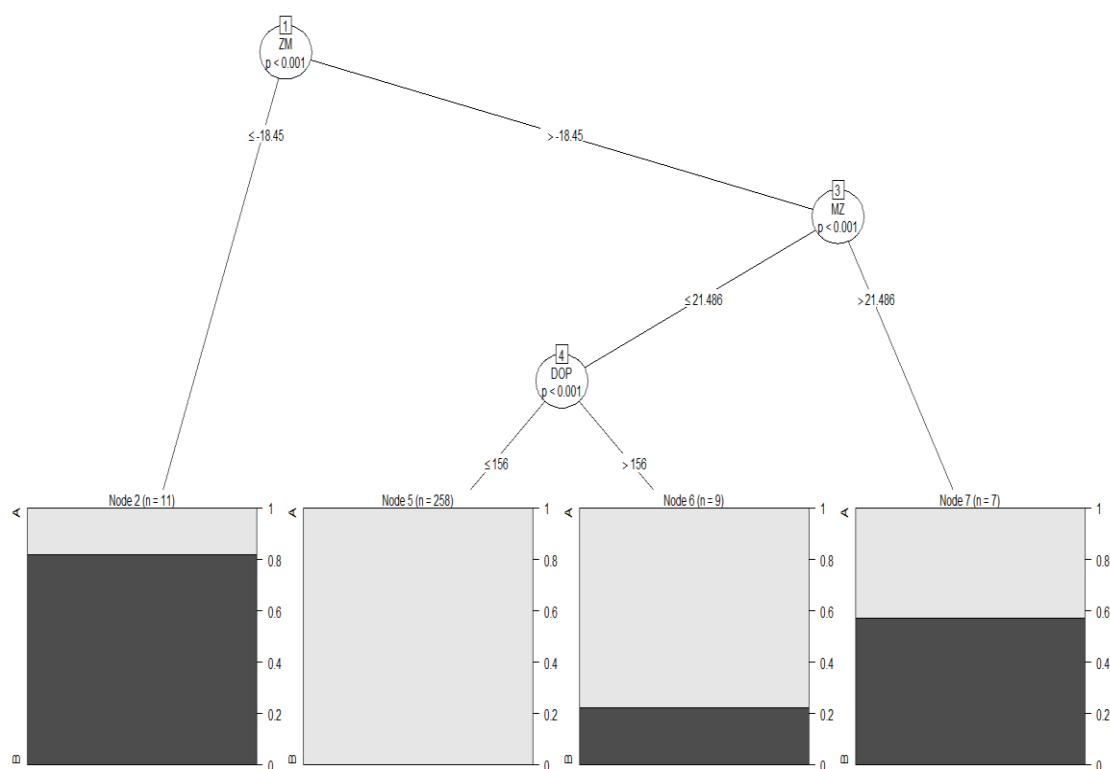
číst, že zhruba v jednom procentu případů model vyhodnotil v současnosti stále aktivní společnosti jako společnost směřující k bankrotu. Z hodnoty chyby I. typu vyplývá, že celkem v 24 % případech byl naopak bankrotní podnik falešně označen jako aktivní. Tento model s polynomickým jádrem může být na základě zjištění hodnoty AUC označen jako model s dobrou klasifikační schopností.

Tab. 26 Míry hodnocení úspěšnosti klasifikace SVM (polynom) model pro rok 2013

Celková správnost	0,97
Senzitivita	0,99
Specifická	0,76
Chyba I. typu	0,01
Chyba II. typu	0,24
AUC	0,91

4.4.2 Výsledky pro rok 2012

I v roce 2012 bude nejprve představen proces učení se modelu pomocí rozhodovacího stromu. Obr. 23 zobrazuje tento proces klasifikace v daném roce.



Obr. 23 Klasifikace pomocí DT pro rok 2012

V rámci tohoto roku byly využity celkem tři proměnné. Stejně jako v roce 2013 i zde to je DOP, tedy doba obratu pohledávek, nově jsou tu však proměnné ZM, tedy zisková marže (jeden z ukazatelů rentability, stejně jako ROA v rámci roku 2013) a MZ, tedy míra zadlužení (jakožto člen skupiny ukazatelů zadluženosti společnosti). Vznikly tak celkem čtyři obdélníky s různým poměrem výplně představující aktivní a zbankrotované společnosti. K prvnímu obdélníku zleva se lze dostat na základě klasifikačního pravidla tvořeného pomocí ziskové marže. Celkem 11 společností bylo ohraničeno pravidlem nižší (popřípadě stejné) ziskové marže, nežli je hodnota -18,45 %. Na základě výplně tohoto obdélníku je možno vidět, že více jak 80 % z těchto společností je skupiny zbankrotovaných společností.

Při postupu po větvi, kde je zisková marže větší jak -18,45 %, se dospěje k uzlu s mírou zadluženosti. Při pokračování po větvi sedm, kde je míra zadluženosti větší jak 21,486, se dojde k obdélníku vpravo. Celkem sedm společností bylo ohraničeno za pomoci tohoto postupu, přičemž skoro 60 % z nich se řadí ke skupině zbankrotovaných společností.

Naopak během postupu po větvi, kde je hodnota míry zadluženosti menší nebo rovna hodnotě 21,486, se nachází další uzel s dobou obratu pohledávek, který rozděluje data dále podle hodnoty 156 dní na společnosti aktivní či zbankrotované. Obdélník v pořadí druhý zprava představuje společnosti se ziskovou marží větší jak -18,45 %, s hodnotou míry zadluženosti menší nebo rovnu číslu 21,486 a dále s hodnotou doby obratu pohledávek větší jak 156 dní. Tímto klasifikačním pravidlem bylo ohraničeno celkem devět společností, přičemž více jak 20 % z nich je zbankrotovaných.

Zbýlých 258 společností, které lze nalézt v rámci druhého obdélníku zleva, se vyznačují naopak hodnotami doby obratu pohledávek kratšími nebo rovny 156 dnům. Bohužel stejně jako v roce 2013, tak i zde jsou jisté nedostatky v rámci této klasifikace. Přesné hodnoty výsledku testování tohoto modelu zaznamenávají následující tři tabulky.

Tab. 27 Kontingenční tabulka pro DT model – absolutní hodnoty pro rok 2012

Predikovaná skupina	Skutečná skupina	
	A	B
A	350	15
B	12	6

Tento model dokázal na základě dat z roku 2012 správně rozdělit 356 společností. Problém se špatných zařazením se zde vyskytl u 12 aktivních a dalších 15 bankrotních společnostech. Podíl jednotlivých správných či nesprávných klasifikací na celkovém souboru dat vyhrazených pro testování modelu zaznamenává Tab. 28.

Tab. 28 Kontingenční tabulka pro DT model – relativní vyjádření pro rok 2012

Predikovaná skupina	Skutečná skupina	
	A	B
	A	0,91
B	0,03	0,02

Na základě vypočtených hodnot v Tab. 28 lze konstatovat, že do nesprávné klasifikační skupiny bylo zařazeno zhruba sedm procent společností – přičemž větší část z nich je tvořena bankrotními společnostmi, které byly modelem přiděleny do skupiny aktivních společností. Ve všech ostatních 93 % případech se skutečná a predikovaná skupina dané společnosti shoduje.

Tab. 29 Míry hodnocení úspěšnosti klasifikace DT model pro rok 2012

Celková správnost	0,93
Senzitivita	0,97
Specifická	0,29
Chyba I. typu	0,03
Chyba II. typu	0,71
AUC	0,69

Ačkoliv je celková správnost (resp. celková chybovost) tohoto modelu uspokojivá, tak zejména výsledky chyby II. typu poukazují na jisté nedostatky. Bohužel se v rámci této klasifikace objevilo relativně mnoho bankrotních společností, které byly na základě výše svých ukazatelů doby obrátu pohledávek, ziskové marže a míry zadlužení nesprávně označeny jako aktivní. Přesněji řečeno pouze 29 % z bankrotních společností bylo správně zařazeno do své klasifikační třídy. Tyto nedostatky modelu se odrazily i v hodnotě AUC, která spadá do intervalu přijatelné klasifikační schopnosti.

Zbývá část výsledků testování přesnosti modelů v roce 2012 se už věnuje modelům sestaveným pomocí metody podpůrných vektorů. Pro toto období bylo na základě gain ratio vybráno a zahrnuto následujících pět finančních ukazatelů: koeficient samofinancování, ROA, zisková marže, celková zadluženost a míra zadluženosti. Stejně jako v předchozím roce i zde byly vytvořeny dva modely s odlišným typem jádra. Nejprve budou prezentovány výsledky modelu s RBF ANOVA jádrem.

Tab. 30 Kontingenční tabulka pro SVM (RBF ANOVA) model – absolutní hodnoty pro rok 2012

Predikovaná skupina	Skutečná skupina	
	A	B
	A	355
B	7	9

SVM model s tímto jádrem nesprávně zařadil celkem 12 bankrotních a dalších sedm aktivních společností z celkového počtu 383 společností vyhrazených pro otestování přesnosti. Ve zbylých 364 případech se model nezmýlil a dané společnosti přiřadil její skutečnou klasifikační skupinu. V Tab. 31 jsou pak obsaženy tyto zjištěné hodnoty v relativním vyjádření.

Tab. 31 Kontingenční tabulka pro SVM (RBF ANOVA) model – relativní vyjádření pro rok 2012

Predikovaná skupina	Skutečná skupina		
	A		B
	A	0,93	0,03
B	0,02	0,02	

Prostým součtem 93 % správně klasifikovaných aktivních společností spolu s dalšími dvěma procenty správně zařazených bankrotních společností získáme hodnotu 95 %, což odpovídá celkové správnosti modelu zaznamenané v Tab. 32. O správnosti tohoto modelu nesvědčí jen hodnota celkové správnosti (a potažmo tak i celkové chybovosti), ale i hodnota AUC, která udává, že se v tomto případě jedná o dobrou klasifikační schopnost modelu. Méně uspokojivé jsou výsledky specificity a logicky proto i chyby II. typu. Bohužel v tomto roce takto nastavený model označil více jak polovinu společností (57 %) ze skupiny těch, které v roce 2014 zbankrotovaly, za společnosti patřící k těm aktivním.

Tab. 32 Míry hodnocení úspěšnosti klasifikace SVM (RBF ANOVA) model pro rok 2012

Celková správnost	0,95
Senzitivita	0,98
Specificita	0,43
Chyba I. typu	0,02
Chyba II. typu	0,57
AUC	0,90

Posledním ze skupiny modelů je SVM model s polynomickým jádrem. Výsledky jeho testování v tomto roce zaznamenává Tab. 33.

Tab. 33 Kontingenční tabulka pro SVM model (polynom) – absolutní hodnoty pro rok 2012

Skutečná skupina	Predikovaná skupina		
	A		B
	A	358	12
B	4	9	

Takto nastavený model dokázal správně zařadit celkem 358 aktivních a dalších devět bankrotních společností. V přepočtu se tedy jedná o správnou klasifikaci 93 % aktivních spolu s dalšími 2 % bankrotních společností z datového souboru

vyhrazeného pro testování modelu. Bohužel ve zbylých čtyřech procentech případech model přidělil dané společnosti nesprávnou skupinu (viz Tab. 34).

Tab. 34 Kontingenční tabulka pro SVM model (polynom) – relativní hodnoty pro rok 2012

Skutečná skupina	Predikovaná skupina	
	A	B
	A	0,93
B	0,01	0,02

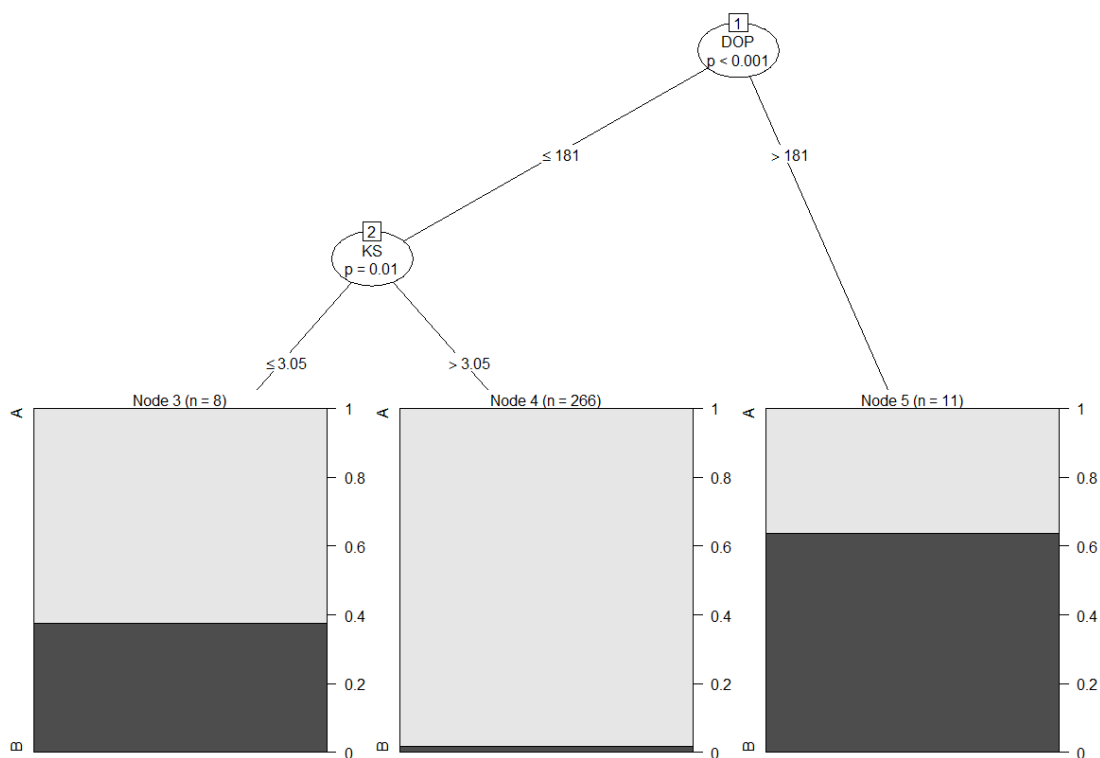
Z hodnot skutečně či falešně pozitivních/negativních výsledků bylo možné vypočítat jednotlivé míry hodnocení úspěšnosti klasifikace. Na základě poměru skutečně aktivních společností ke všem společnostem, které model označil jako aktivní (tj. senzitivita), lze hovořit o velmi dobrých výsledcích v rámci této klasifikace. Bohužel hodnoty specificity (a tím i chyby II. typu) snižují celkovou úspěšnost modelu. Nesprávné zařazení celkově čtyř procent společností z datového souboru 383 společností vyhrazených pro testování modelu ovlivnilo i hodnotu AUC, která spadá do intervalu pro dobrou klasifikační schopnost. Přesné hodnoty pro tyto míry hodnocení jsou zaznamenány v Tab. 35.

Tab. 35 Míry hodnocení úspěšnosti klasifikace SVM (polynom) model pro rok 2012

Celková správnost	0,96
Senzitivita	0,99
Specificita	0,43
Chyba I. typu	0,01
Chyba II. typu	0,57
AUC	0,88

4.4.3 Výsledky pro rok 2011

Stejně tak jako v ostatních sledovaných obdobích i zde bude nejprve předvedena fáze učení se DT modelu. Na Obr. 24 jsou zobrazeny proměnné použité v rámci klasifikace 285 společností z tréninkové množiny.



Obr. 24 Klasifikace pomocí DT pro rok 2011

Na rozhodovacím stromu je možno vidět, že model využil dvě proměnné: DOP, tedy dobu obratu pohledávek (stejně jako v předchozích letech) a KS, což je zkratka pro koeficient samofinancování (jeden z ukazatelů zadluženosti). Stejně tak jako v roce 2013 vznikly tři obdélníky s různým podílem světlé a tmavé barvy, který ukazuje podíl dané skupiny aktivních/zbankrotovaných společností ve výseku v rámci stromu.

Zcela vpravo jsou k nalezení společnosti, které se vyznačují svojí dobou obratu pohledávek vyšší jak 181 dní. Přičemž tímto postupem bylo ohraničeno celkem 11 společností, avšak pouze něco málo přes 60 % z těchto společností je ze skupiny zbankrotovaných. Platí tedy, že společnosti nejsou zcela jednoznačně bankrotní.

Při postupování po větvi, kde je doba obratu pohledávek nižší nebo rovna hodnotě 181 dní, se objeví druhý ukazatel, koeficientu samofinancování, který data dále rozděluje podle hodnoty 3,05 na zbankrotované a nezbankrotované. Avšak v rámci daného datového souboru se našly i takové případy společností, které měly sice hodnotu koeficientu samofinancování nižší než je tato hraniční hodnota 3,05 a přitom v budoucnu nebankrotovaly.

Tab. 36 Kontingenční tabulka pro DT model – absolutní hodnoty pro rok 2011

Predikovaná skupina	Skutečná skupina	
	A	B
	A	353
B	9	4

Tab. 36 zaznamenává už výsledky testování výše popsaného modelu. V roce 2011 bylo pomocí tohoto modelu správně zařazeno celkem 357 společností. Zbýlých 17 bankrotních a dalších devět aktivních společností bylo však přiřazeno do nesprávné klasifikační třídy. Podíl těchto správných a nesprávných klasifikací na celkovém souboru dat vyhrazených pro testování obsahuje Tab. 37.

Tab. 37 Kontingenční tabulka pro DT model – relativní vyjádření pro rok 2011

Predikovaná skupina	Skutečná skupina	
	A	B
	A	0,92
B	0,02	0,01

Z uvedených kontingenčních tabulek bylo možné vyjádřit jednotlivé míry hodnocení úspěšnosti této klasifikace (viz Tab. 38). Celková správnost modelu dosáhla hodnoty 93 %. Jelikož model nesprávně označil jen pouhá 2 % společností jako bankrotní, ačkoliv patří ke skupině aktivních společností, tak jsou zjištěné hodnoty senzitivity a chyby I. typu uspokojivé. Větší problémy nastaly při zařazování bankrotních společností, což se odráží v hodnotách chyby II. typu a specificity. Celkově bylo 81 % z bankrotních společností chybě klasifikováno jako nezbankrotované. Dále lze na základě hodnoty AUC označit tuto klasifikační schopnost modelu jako přijatelnou.

Tab. 38 Míry hodnocení úspěšnosti klasifikace DT model pro rok 2011

Celková správnost	0,93
Senzitiva	0,98
Specificita	0,19
Chyba I. typu	0,02
Chyba II. typu	0,81
AUC	0,65

Další skupina tabulek se věnuje už modelům s metodou podpůrných vektorů. V roce 2011 tyto dva modely pracují dle výběru pomocí gain ratio s těmito proměnnými: koeficient samofinancování, ROA, doba obratu závazků, celková zadluženost a míra zadluženosti. Nejprve budou představeny výsledky modelu s RBF ANOVA jádrem.

Tab. 39 Kontingenční tabulka pro SVM model (RBF ANOVA) – absolutní hodnoty pro rok 2011

Predikovaná skupina	Skutečná skupina	
	A	B
	A	359
B	3	7

Takto nastavený model dokázal správně zařadit celkem 366 z celkového počtu 383 společností. Neuspěl tedy v zařazení 14 bankrotních a dalších tří aktivních společností. Tab. 40 zaznamenává tyto dosažené výsledky v relativním vyjádření.

Tab. 40 Kontingenční tabulka pro SVM model (RBF ANOVA) – relativní vyjádření pro rok 2011

Predikovaná skupina	Skutečná skupina	
	A	B
	A	0,94
B	0,01	0,02

Na základě zjištěných výsledků klasifikace v tomto roce můžeme přistoupit k hodnocení modelu na základě hodnot z Tab. 41.

Tab. 41 Míry hodnocení úspěšnosti klasifikace SVM (RBF ANOVA) model pro rok 2011

Celková správnost	0,96
Senzitivita	0,99
Specifická	0,33
Chyba I. typu	0,01
Chyba II. typu	0,67
AUC	0,87

Celková správnost tohoto modelu dosahuje 96 %. Dle chyby I. typu lze dále konstatovat, že pouhé jedno procento z aktivních společností bylo nesprávně zařazeno do skupiny bankrotních. Méně uspokojivých výsledků model dosáhl v rámci skupiny bankrotních podniků – celých 67 % ze zbankrotovaných společností bylo zařazeno do nesprávné skupiny. Podle výsledné hodnoty AUC má tento model dobrou klasifikační schopnost.

Tab. 42 Kontingenční tabulka pro SVM model (polynom) – absolutní hodnoty pro rok 2011

Skutečná skupina	Predikovaná skupina	
	A	B
	A	350
B	12	7

I v roce 2011 uzavírá skupinu sestavených modelů SVM model s polynomickým jádrem. Jak je vidět z hodnot uvedených v Tab. 42, tak tento model dokázal správně klasifikovat celkem 350 aktivních a dalších sedm bankrotních společností. Ve zbylých 26 případech se však skutečná a predikovaná skupina neshoduje. Podíl těchto správných a nesprávných zařazení na celkovém souboru dat vyhrazeném pro testování zaznamenává Tab. 43.

Tab. 43 Kontingenční tabulka pro SVM model (polynom) – relativní hodnoty pro rok 2011

Skutečná skupina	Predikovaná skupina	
	A	B
	A	0,91
B	0,03	0,02

Ze zjištěných výsledků klasifikace takto nastaveného modelu bylo možné vypočítat i míry hodnocení přesnosti klasifikace, které jsou k nalezení v Tab. 44.

Tab. 44 Míry hodnocení úspěšnosti klasifikace SVM (polynom) model pro rok 2011

Celková správnost	0,93
Senzitivita	0,97
Specifická	0,33
Chyba I. typu	0,03
Chyba II. typu	0,67
AUC	0,67

Ačkoliv celková správnost tohoto modelu dosahuje 93 %, tak tři procenta z aktivních a navíc celých 67 % ze skupiny bankrotních společností bylo klasifikováno nesprávně. Tyto neúspěchy se projeví i v samotné hodnotě AUC, jež spadá do intervalu pro přijatelnou klasifikační schopnost.

5 Závěr a diskuze

Jak již bylo v této práci zmíněno, od druhé poloviny minulého století, kdy se oblasti hodnocení finančního zdraví podniku začala více věnovat pozornost, vzniklo nespočetné množství modelů pro hodnocení finanční situace podniku. Tato práce poukazuje na možnost využití metod vícerozměrné statistiky a dolování dat při predikci bankrotu. Hlavním cílem této práce bylo vyhodnotit přesnost modelů založených na metodě podpůrných vektorů pro predikci bankrotu strojírenských společností v EU. Snahou práce tedy bylo zjistit, zda a do jaké míry přesnosti je možné předpovídat bankrot společnosti s předstihem až celých tří let dopředu. Pro naplnění tohoto cíle byly vybudovány dva modely založené na zmíněné metodě podpůrných vektorů s odlišným typem jádra (přesněji RBF ANOVA jádra a polynomiálního jádra druhého stupně). Do opozice k této metodě byl pak postaven model sestavený na základě metody rozhodovacích stromů.

Kvůli dosažení homogennějšího souboru dat byly do práce zahrnuty pouze strojírenské společnosti – kde byly navíc vybírány jen malé a středně velké společnosti. Aby bylo možné získat potřebné množství zejména bankrotních společností, bylo nutné zaměřit se na celou oblast Evropské unie, ačkoliv panují určité rozdíly v rámci ekonomik jednotlivých států. Získat dostatečné množství bankrotních společností byl celkově problém při zpracování této práce. Často byly výkazy společností v rámci databáze Amadeus neúplné. V takových případech bylo nutné dané subjekty ze souboru dat vyloučit, popřípadě vyloučit celý finanční ukazatel, aby se předešlo zúžení datového souboru. Jelikož byla práce zaměřena na oblast detekce bankrotu v časovém předstihu, tak byla ze zmiňované databáze vybrána data z let 2011 až 2013. Aktuálnější hodnoty (v požadovaném rozsahu a úplnosti) nebylo možné během zpracování této práce získat. Celkem bylo do práce zařazeno 902 aktivních společností a dalších 51 společností, které lze v roce 2014 považovat za zbankrotované. Poměr bankrotních a aktivních společností proto není v souboru dat vyrovnán, což se poté promítlo v hodnotách celkové správnosti (i celkové chybovosti) v rámci jednotlivých zkoumaných modelů. Proto bylo nezbytné vyjádřit si samostatně i chyby I. a II. typu každého modelu, aby se při vyhodnocování přesnosti daného modelu neztrácela chybovost klasifikace těchto v souboru méně čítných zbankrotovaných společností. Naopak lze díky tomu tento soubor dat s převahou fungujících společností označit jako více realistický, neboť lépe odpovídá situaci na trhu, kde se v současné době vyskytuje mnohonásobně více aktivních společností nežli těch, které ohlásily bankrot.

Následně bylo s ohledem na finanční teorie vybráno celkem 14 ukazatelů zastupující čtyři základní skupiny finančních ukazatelů (tj. ukazatelů zadluženosti, rentability, aktivity a likvidity), se kterými se dále pracovalo při následujících analýzách i při samotné výstavbě jednotlivých modelů²⁸. Pro každý z těchto 14 zvole-

²⁸ Během výstavby modelů bylo u metody SVM využito selekce na pět proměnných pomocí míry hodnocení přes gain ratio. V rámci DT modelu nebylo využito žádné dodatečné filtrace (metoda sama o sobě provádí výběr proměnných).

ných ukazatelů byly následně vypočteny základní statistické charakteristiky polohy s ohledem na dvě sledované skupiny společností. Další rozdíly mezi aktivními a zbankrotovanými společnostmi byly sledovány i pro skupiny nejvíce a nejméně ziskových společností z obou souborů. Dále byla provedena analýza hlavních komponent a na ni navazující shluková analýza, která poukázala na společné ale i rozdílné rysy mezi aktivními a bankrotními společnostmi.

Poslední část této práce byla zaměřena na testování přesnosti vybudovaných modelů. Pro každé ze tří sledovaných období byly sestaveny výše zmíněné tři modely, aby bylo možné sledovat případné změny ve výsledcích přesnosti (a tedy i chybovosti) jednotlivých modelů s prodlužující se dobou od bankrotu. Zajímavé bylo pozorovat na základě jakých proměnných v jednotlivých letech DT a SVM modely prováděly klasifikaci. Během žádného ze tří sledovaných období nedošlo k úplné shodě v rámci použitých ukazatelů²⁹. V roce 2013 byla dokonce klasifikace prováděna pomocí zcela odlišných proměnných. Dle SVM modelů je pro odhalení společnosti směřující k bankrotu nejlépe sledovat zejména hodnoty ukazatelů zadluženosti (koeficient samofinancování, celková zadluženost a míra zadlužení) spolu s ukazateli rentability (zisková marže, popřípadě rentabilita aktiv). Naopak DT model při klasifikaci využil ve všech třech obdobích i ukazatel doby obratu pohledávek v kombinaci s dalšími již vyjmenovanými ukazateli v rámci SVM modelů. I přes tuto rozdílnost – zejména v roce 2013 – dosáhly vybudované modely obdobných výsledků v rámci celkové přesnosti i chyby I. typu.

Hodnoty celkové správnosti všech modelů pro roky 2011 až 2013 jsou nadmíru uspokojivé, avšak s rostoucí dobou od roku bankrotu klesá predikční schopnost všech těchto modelů. Pokles hodnot lze také pozorovat i na samotných hodnotách senzitivity, specificity a tím i hodnot AUC. Počet chybných klasifikací zejména v ústřední skupině zbankrotovaných společností se s prodlužující dobou (období dvou a více let před bankrotem) významně rozrůstá. Možným řešením tohoto problému by mohlo být zapojení většího množství bankrotních společností umožněného například rozšířením okruhu vybraných oborů nebo rozšířením geografické oblasti, ze které budou společnosti vybrány. Obě tyto možnosti s sebou však nesou jisté riziko spojené se specifiky oboru či oblasti. Avšak výsledky i takovéhoho bádání by mohly přinést nové poznatky. Dále bylo v práci zjištěno, že zvolený soubor dat dokázal přesněji klasifikovat SVM model oproti DT modelu (viz Tab. 45). SVM model s RBF ANOVA jádrem v roce 2013 pochybil při klasifikaci pouze u deseti procent společností ze skupiny zbankrotovaných společností, což je lepší výsledek o 13–23 procentních bodů v porovnání s ostatními dvěma modely. Přičemž celková chybovost zde dosahovala pouhých dvě procenta.

²⁹ Proměnné z obou (resp. všech tří) skupin modelů však reflektují poznatky získané v rámci shlukové analýzy ohledně typických a rozdílných vlastností aktivních a bankrotních společností.

Tab. 45 Celková správnost vybudovaných modelů pro všechna sledovaná období

Model	Celková správnost (%)
DT 2013	97
SVM RBF ANOVA 2013	98
SVM polynom 2013	97
DT 2012	93
SVM RBF ANOVA 2012	95
SVM polynom 2012	96
DT 2011	93
SVM RBF ANOVA 2011	96
SVM polynom 2011	93

Výsledek této práce je tedy přesně opačný nežli například u studie Li, Sun a Wu (2010), kde klasifikační stromy překonaly metodu SVM. Toto zjištění by bylo možné odůvodnit odlišně zvolenou metodou selekce při výstavbě SVM modelu. Zde se lze odkázat na práci Klepáče a Hampela (2016), ve které byly demonstrovány účinky odlišných typů jader v kombinaci s různými typy selekce na chybovost jednotlivých modelů. Ohledně samotné metody SVM se v rámci této práce také potvrdilo, že při využití RBF jádra lze dosáhnout celkově lepších výsledků nežli s jiným (v tomto případě polynomickým) typem jádra, jak tvrdí ve své studii například Sun a Li (2012).

Úspěšnost dosažených výsledků je viditelná i při srovnání s celkovou správností SVM u jiných studií (viz Tab. 46) – rozdíly jsou zde o několik procentních bodů.

Tab. 46 Celková přesnost SVM ve vybraných studiích

Celková správnost SVM (%)	Vzorek dat	Autoři studie
83	1888 společností	Min a Lee 2005
89	270 společností	Li, Sun a Wu 2010
93	660 společností	Niknya, Darabi a Fard 2013

SVM metody bezpochyby nabízejí široké spektrum možností využití. Jak již bylo v práci zmíněno, tak stále existuje prostor pro zkoumání výsledků při různém nastavení. Existuje zde možnost zaměřit se na typy selekce, jádra, výsledky by se mohly zpřesnit i pomocí odlišného rozdělení tréninkového, validačního a testovacího setu. Při této práci byl zvolen poměr těchto dílčích setů jako 30/30/40 %, ale například Min a Lee (2005) ve své práci zvolili rozdělení 60/20/20 %. Přesnost takovýchto modelů by se mohla následně porovnávat i s dalšími metodami (neuronové sítě, *k*-nejbližšího souseda atd.) obdobně jako Ding, Song a Zen (2008) či Min a Lee (2004) ve svých studiích. Přínosné by byly i výsledky získané při použití takovýchto modelů v rámci klasifikace více stavů společností.

6 Literatura

- ALTMAN, E. *Financial Ratios, Discriminand Analysis and the Prediction of Corporate Bankruptcy*. The Journal of Finance: 1968. vol. 23, No. 4, 589-609.
- BŘEŇ, S. *Anketa: Růst strojírenství by měl pokračovat i v roce 2016*. [online]. 2015-09-08 [cit. 2015-12-05]. Dostupné z: <http://exportadores.czechtrade-espana.com/o-czechtrade/reference/czechtrade-media/anketa-rust-strojirenstvi-by-mel-pokracovat-i-v-roce-2016-17-9-2015/>.
- ČESKÝ STATISTICÝ ÚŘAD:: *Demografie podniků - hlavní ukazatele (NACE Rev.2: B-N s výjimkou K64.2)* [online]. 2016-02-09 [cit. 2015-12-05]. Dostupné z: <http://apl.czso.cz/pll/eutab/html.h?ptabkod=tin00170>.
- DING, Y., SONG X., ZEN, Y. *Forecasting financial condition of Chinese listed companies based on support vector machine*. Expert Systems with Applications. 2008, roč. 34, vyd. 4, s. 3081-3089. DOI: 10.1016/j.eswa.2007.06.037.
- DOSTÁL, P., RAIS, K., SOJKA, Z. *Pokročilé metody manažerského rozhodování*. 1. vyd. Praha: Grada, 2005. ISBN 80-247-1338-1.
- EUROSTAT: *National accounts and GDP* [online]. 2015 [cit. 2015-12-04]. Dostupné z: http://ec.europa.eu/eurostat/statistics-explained/index.php/National_accounts_and_GDP.
- FRISTAM PUMPEN [online]. 2016 [cit. 2016-02-22]. Dostupné z: <http://www.fristam.de/en/>.
- GEPP, A., KUMAR, K. *Predicting Financial Distress: A Comparison of Survival Analysis and Decision Tree Techniques*. Procedia Computer Science. 2015, roč. 54, s. 396-404. DOI: 10.1016/j.procs.2015.06.046.
- HOLČÍK, J. *Analýza a klasifikace dat*. 1. vyd. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-793-2.
- HORÁČEK, F. *Nezaměstnaných v Německu ubylo, strojírenství se ale drasticky zhoršilo*. [online]. 2009 [cit. 2015-11-01]. Dostupné z: http://ekonomika.idnes.cz/nezamestnanych-v-nemecku-ubylo-strojirenstvi-se-ale-drasticky-zhorsilo-1qd-/eko-zahranicni.aspx?c=A090528_102612_eko-zahranicni_fih.
- HUARNG, K., YU H. K., CHEN C. J. *The application of decision trees to forecast financial distressed companies*. Proceeding sof International Conference on Intelligent Technologies and Applied Statistics, Taipei, Taiwan, 2005.
- CHEN, W. S., DU, Y. K. *Using neural networks and data mining techniques for the financial distress prediction model*. Expert Systems with Applications. 2009, roč. 36, vyd. 2, s. 4075-4086. DOI: 10.1016/j.eswa.2008.03.020.
- INDUSTRY EU. *Katalog firem - Strojírenství* [online]. 2012 [cit. 2015-11-01]. Dostupné z: <http://www.industry-eu.cz/strojirenstvi/?nuts=0>.
- JANÁČKOVÁ, S. *Krize eurozóny a dluhová krize vyspělého světa*. 1. vyd. Praha: Centrum pro ekonomiku a politiku, 2010. ISBN 978-80-86547-95-4.

- JANÍČEK, P., MAREK, J., A KOL. *Expertní inženýrství v systémovém pojetí*. 1. vyd. Praha: Grada, 2013. ISBN 978-80-247-4127-7.
- JANOŠKOVÁ, E., HOLČÍK, J., A KOL. *Vícerozměrné metody pro analýzu a klasifikaci dat* [online]. Institut biostatistiky a analýz Masarykova univerzita 2015 [cit. 2016-01-07]. Dostupné z: <http://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologicky-ch-dat--vicerozmerne-metody-pro-analyzu-dat>.
- JAROŠOVÁ, E., NOSKIEVIČOVÁ, D. *Pokročilejší metody statistické regulace procesu*. 1. vyd. Praha: Grada, 2015. ISBN 978-80-247-5355-3.
- JOLLIFFE, I. T. *Principal components analysis*. 2. vyd. New York: Springer, 2002. ISBN 978-0-387-22440-4.
- KIM, Y. S., UPNEJA, A. *Predicting restaurant financial distress using decision tree and Ada Boosted decision tree models*. Economic Modelling. 2014, roč. 36, s. 354-362. DOI: :10.1016/j.econmod.2013.10.005.
- KISLINEROVÁ, E., HNILICA, J. *Finanční analýza: krok za krokem*. 2. vyd. Praha: C. H. Beck, 2008. ISBN 978-80-7179-713-5.
- KISLINEROVÁ, E., A KOL. *Manažerské finance*. 3. vyd. Praha: C. H. Beck, 2010. ISBN 978-80-7400-194-9.
- KLEPÁČ, V., KAMARÝTOVÁ, S. *Using Support vector machines for classification of retail companies from the point of financial risk*. XXXIII International Colloquium on the Management of Educational Process. 33. vyd. Brno: University of Defence.
- KLEPÁČ, V., HAMPEL, D. *Prediction of bankruptcy with SVM classifiers among retail business companies in EU*. Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis. 2016, roč. 64, vyd. 2, s. 627-634. DOI: 10.11118/actaun201664020627.
- KNÁPKOVÁ, A., A KOL. *Finanční analýza: komplexní průvodce s příklady*. 2. vyd. Praha: Grada, 2013. ISBN 978-80-247-4456-8.
- KRAFTOVÁ, I. *Finanční analýza municipální firmy*. 1. vyd. Praha: C. H. Beck, 2002. ISBN 80-7179-778-2.
- KUČERA, J. *Hierarchické metody shlukování* [online]. 2008 [cit. 2016-01-05]. Dostupné z: http://is.muni.cz/th/172767/fi_b/5739129/web/web/hiermet.html#al.
- LI, H., SUN, J., WU, J. *Predicting business failure using classification and regression tree: An empirical comparison with popular classical statistical methods and top classification mining methods*. Expert Systems with Applications. 2010, roč. 37, vyd. 8, s. 5895-5904 DOI: 10.1016/j.eswa.2010.02.016.
- LIN, Y. F., MCCLEAN, S. *A data mining approach to the prediction of corporate failure*. Knowledge-Based Systems. 2001, roč. 14, vyd. 3-4, s. 189-195. DOI: 10.1016/S0950-7051(01)00096-X.
- LIPO, W. *Support vector machines: Theory and applications*. 2. vyd. New York: Springer, 2005. ISBN 978-3-540-24388-5.

- MANAGEMENTMANIA. *Likvidita z cash flow* [online]. 2015 [cit. 2016-01-15]. Dostupné z: <https://managementmania.com/cs/likvidita-z-cash-flow>.
- MARINIČ, P. *Plánování a tvorba hodnoty firmy*. 1. vyd. Praha: Grada, 2008. ISBN 978-80-247-2432-4.
- MELOUN, M., MILITKÝ, J. *Přednosti analýzy shluků ve vícerozměrné statistické analýze* [online]. 2006 [cit. 2016-01-10]. Dostupné z: <http://meloun.upce.cz/docs/publication/152.pdf>.
- MIN, H. J., LEE, C. Y. *Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters*. Expert Systems with Applications. 2005, roč. 28, vyd. 4, s. 603-614 DOI: 10.1016/j.eswa.2004.12.008.
- MIN, H. J., LEE, J., HAN, I. *Hybrid genetic algorithms and support vector machines for bankruptcy prediction*. Expert Systems with Applications. 2006, roč. 31, vyd. 3, s. 652-660 DOI: 10.1016/j.eswa.2005.09.070.
- MULAČ, P., MULAČOVÁ, V. *Obchodní podnikání ve 21. století*. 1. vyd. Praha: Grada, 2013. ISBN 978-80-247-4780-4.
- NEUMAIEROVÁ, I., NEUMAIER, I. *Výkonnost a tržní hodnota firmy*. 1. vyd. Praha: Grada, 2002. ISBN 80-247-0125-1.
- NIKNYA, A., DARABI, R., FARD, V. H. R. *Financial Distress Prediction of Tehran Stock Exchange Companies Using Support Vector Machines*. European Online Journal of Natural and Social Science 2013, roč. 2. Special Issue on Accounting and Management. ISSN 1805-3602.
- NOVOTNÝ, O., POUR, J., SLÁNSKÝ, D. *Business Intelligence – Jak využít bohatství ve vašich datech*. 1. vyd. Praha: Grada, 2005. ISBN 978-80-247-6685-0.
- OHLSON, J. A. *Financial ratios and the probabilistic prediction of bankruptcy*. Journal of Accounting Research. 1980, vol. 18, No. 1, 109-131. DOI: 10.2307/2490395.
- PALEPU, K. G., HEALY, P. M., PEEK, E. *Business analysis and valuation: Text and Cases*. 3. vyd. Hampshire: Cengage Learning, 2013. ISBN 978-1-4080-5642-4.
- PEŠKOVÁ, R., JINDŘICHOVSKÁ, I. *Finanční analýza*. 2. vyd. Praha: Vysoká škola ekonomie a managementu, 2012. ISBN 978-80-86730-89-9.
- PROCHÁZKA, M. *Data mining: Jiný pohled na problém* [online]. 2012 [cit. 2016-01-05]. Dostupné z: <http://vtm.e15.cz/aktuality/data-mining-jiny-pohled-na-problem>.
- REŽŇÁKOVÁ, M., A KOL. *Řízení platební schopnosti podniku*. 1. vyd. Praha: Grada, 2010. ISBN 978-80-247-3441-5.
- ROKACH, L., MAIMON, O. *Data mining with decision trees: Theory and Applications*. 2. vyd. London: World Scientific, 2015. ISBN 978-9814590082.
- RŮČKOVÁ, P. *Finanční analýza: metody, ukazatele, využití v praxi*. 5. vyd. Praha: Grada, 2015. ISBN 978-80-247-5534-2.
- ŘEZANKOVÁ, H., HÚSEK, D., SNÁŠEL, V. *Shluková analýza dat*. 1. vyd. Praha: Professional Publishing, 2007. ISBN 978-80-86946-26-9.

- SEBERA, M. *Analýza hlavních komponent a Faktorová analýza* [online]. 2012 [cit. 2016-01-05]. Dostupné z: http://www.fsps.muni.cz/~sebera/vicerozmerna_statistika/pca.html.
- SHIN, K. S., LEE, S. T., KIM, J. H. *An application of support vector machines in bankruptcy prediction model*. *Expert Systems with Applications*. 2005, roč. 28, vyd. 1, s. 127-135 DOI: 10.1016/j.eswa.2004.08.009.
- SUN, J., LI, H. *Financial distress prediction using support vector machines: Ensemble vs. individual*. *Applied Soft Computing*. 2012, roč. 12, vyd. 8, s. 2254-2265 DOI: 10.1016/j.asoc.2012.03.028.
- SYNEK, M., A KOL. *Manažerská ekonomika*. 5. vyd. Praha: Grada, 2011. ISBN 978-80-247-3494-1.
- ŠIMAN, J., PATERA, P. *Financování podnikatelských subjektů*. 1. vyd. Praha: C. H. Beck, 2010. ISBN 978-80-7400-117-8.
- TECHNICKÝ TÝDENÍK. *Strojírenství je stále oporou českého průmyslu* [online]. 2014 [cit. 2015-11-01]. Dostupné z: http://www.technickytydenik.cz/rubriky/archiv/strojirenstvi-je-stale-oporou-ceskeho-prumyslu_27899.html.
- TSAKONAS, A., DOUNIAS, G., DOUMPOS, M., ZOPOUNIDIS, C. *Bankruptcy prediction with neural logic networks by means of grammar-guided genetic programming*. *Expert Systems with Applications*. 2006, roč. 30, vyd. 3, s. 449-461 DOI: 10.1016/j.eswa.2005.10.009.
- TSUKUDA, J., BABA I. S. *Predicting japanese corporate bankruptcy in terms of financial data using neural network*. *Computers&Industrial Engineering*. 1994, roč. 27, vyd. 1-4, s. 445-448 DOI: 10.1016/0360-8352(94)90330-1.
- TVRDÍKOVÁ, M. *Aplikace moderních informačních technologií v řízení firmy*. 1. vyd. Praha: Grada, 2008. ISBN 978-80-247-2728-8.
- VAPNIK, V. N. *The nature of statistical learning theory*. 2. vyd. New York: Springer, 1999. ISBN 0-387-98780-0.
- VIGIER, P., ET AL. *Innovation Union Competitiveness report 2013*. 2. vyd. Luxembourg: Publications Office of the European Union, 2014. ISBN 978-92-79-27961-4.
- VOCHOZKA, M. *Metody komplexního hodnocení podniku*. 1. vyd. Praha: Grada, 2011. ISBN 978-80-247-3647-1.
- ZMIJEWSKI, M. E. *Methodological Issues Related to the Estimation of Financial Distress Prediction Models*. *Journal of Accounting Research*. 1984, vol. 22. DOI: dx.doi.org/10.2307/2490859.