

Užití kopula funkce pro odhad kreditního rizika podniku

Disertační práce

Vedoucí práce:

doc. Mgr. Ing. Jitka Janová, Ph.D.

Vypracoval:

Ing. Václav Klepáč

Brno 2016

Poděkování

Na tomto místě bych rád poděkoval vedoucí dizertační práce doc. Mgr. Ing. Jitce Janové, Ph.D. za metodické vedení při zpracování tématu předkládané dizertační práce. Děkuji také své rodině za podporu při celé době studia.

Čestné prohlášení

Prohlašuji, že jsem svoji práci na téma: „Užití kopula funkce pro odhad kreditního rizika podniku“ vypracoval 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 vědom/a, 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: 18. 8. 2016

.....
podpis

Abstrakt

KLEPÁČ, V. *Užití kopula funkce pro odhad kreditního rizika podniku*. Brno, 2016. Dizertační práce. Mendelova univerzita v Brně.

Práce se zabývá problematikou predikce finanční situace nefinančních společností s veřejně obchodovanými akciemi v ČR a EU. Využity jsou původní účetních a strukturálních modely kreditního rizika, díky kterým vyčíslujeme výši pravděpodobnosti defaultu. Práce se blíže zaměřuje na aplikaci Mertonova, Altmanova a Ohlsonova modelu v základní teoretické podobě pro získání pravděpodobnosti defaultu nebo bankrotu. Díky přispění moderních vícerozměrných ekonometrických a simulačních přístupů rozšiřujeme původní Mertonův model o teorii vícerozměrných D-Vine kopulí, pomocí kterých přenášíme závislost mezi vývojem na finančním trhu do struktury závislosti podnikových aktiv společností, které jsou významným indikátorem pro výpočet pravděpodobnosti defaultu. V dalších krocích vycházíme z tvorby predikčních modelů na základě metody podpůrných vektorů a rozhodovacích stromů pro účely klasifikace finančních obtíží podniku v podobě ukazatele zadluženosti nebo likvidity. K tomuto účelu využíváme různou podobu a četnost vstupních proměnných – účetní, tržní a kombinovaná data spolu s odvozenými pravděpodobnostmi defaultu, resp. finančního ohrožení.

Klíčová slova: D-Vine kopula funkce, finanční analýza, klasifikace, Mertonův model, strukturální modely kreditního rizika.

Abstract

KLEPÁČ, V. *Using copula function for corporate credit risk estimation*. Brno, 2016. Dissertation thesis. Mendel University in Brno.

This thesis is focused on the problems of the prediction of financial situation of non-financial companies in the Czech Republic and the European Union with shares publically traded on the stock exchange. It is based on the original accounting and structural models of credit risk which enable to enumerate the probability of default. The application of Merton, Altman and Ohlson model in their basic theoretical form for the determination of the probability of default or bankruptcy is dealt with in detail. Modern multi-dimensional econometric and simulation approaches enabled to extend the original Merton model, adding the theory of multi-dimensional D-Vine copulas which project the dependency between the development on the financial market into the structure of dependency of company assets of companies, which serve as a significant indicator for the calculation of the probability of default. Next steps proceed from the creation of prediction models based on the SVM method and decision trees for the purpose of classification of company financial difficulties which are represented by the debt index or liquidity index. Different forms and numbers of input variables are used for this purpose: accounting, market and combined data together with the derived probabilities of default, or more precisely of financial distress.

Klíčová slova: classification, D-Vine copula, financial analysis, Merton model, structural credit risk models.

Obsah

1	Úvod a cíl práce	15
1.1	Úvod.....	15
1.2	Cíl práce.....	18
1.3	Praktické přínosy.....	18
2	Základní pojmy	20
3	Literární rešerše	23
3.1	Krise, finanční tíseň a default podniku	23
3.1.1	Příčiny krize.....	26
3.1.2	Fáze a příznaky krize.....	27
3.2	Geneze modelů kreditního rizika.....	28
3.2.1	Účetní modely	32
3.2.1.1	Altmanův model.....	32
3.2.1.2	Altmanův ZETA model.....	34
3.2.1.3	Altmanův model pro rozvíjející se trhy	35
3.2.2	Ohlsonův model	36
3.2.3	Strukturální modely	37
3.2.3.1	Mertonův model.....	38
3.2.4	Měření závislostí kreditního rizika.....	41
3.2.4.1	Korelace a kopula funkce	42
3.3	Empirické testování metod pro měření kreditního rizika a bankrotu	44
3.3.1	Vybrané studie o využití algoritmu podpurných vektorů a rozhodovacích stromů k predikci bankrotu	46
3.3.2	Empirické aplikace strukturálních modelů	48
4	Materiál a metody	52
4.1	Materiál	52
4.2	Metodické kroky a použité kvantitativní techniky	52
4.2.1	Finanční analýza	53

4.2.2	Poměrové ukazatele v bankrotních modelech.....	54
4.2.3	Odhad pravděpodobnosti defaultu společností.....	57
4.2.3.1	Odhady modelů volatility pro účely strukturálních modelů rizika	60
4.2.3.2	Aplikace Vine kopula funkce na datech finančního trhu	60
4.2.4	Sestavení algoritmu Merton-D-Vine kopula	63
4.3	Data miningová analýza a klasifikace.....	65
4.3.1	Klasifikace pomocí shlukové analýzy.....	67
4.3.2	Klasifikace pomocí metody podpůrných vektorů.....	68
4.3.3	Klasifikace pomocí metody rozhodovacích stromů.....	71
4.3.4	Základní vyhodnocení přesnosti klasifikace – kontingenční tabulka	72
5	Vlastní práce	74
5.1	Základní statistické charakteristiky datového setu.....	74
5.1.1	Shluková analýza dle finančních ukazatelů.....	76
5.2	Odhad finanční situace společností pomocí účetních modelů	79
5.2.1	Altmanův a Ohlsonův model.....	79
5.3	Odhad pravděpodobnosti defaultu pomocí strukturálních modelů rizika.....	86
5.3.1	Odhady volatility a přiřazení rizika	86
5.3.1	Odhad D-Vine kopula GARCH modelů	92
5.3.2	Odhad rizika pomocí Mertonova a Mertonova D-Vine kopula modelu ..	95
5.3.3	Shrnutí průběžných výsledků	101
5.4	Klasifikace společností a vyhodnocení predikční síly modelů	104
6	Diskuze	112
7	Závěr	116
8	Literatura	120
A	Základní statistické charakteristiky a složení komponent	129
B	Dendrogramy pro proměnné vstupující do klasifikace a struktury závislosti kopula modelu	135
C	Sumarizace vstupních dat a jiné	145

Seznam obrázků

Obr. 1 Příklady D-Vine a C-Vine stromu pro pět proměnných, na levé straně jsou vzorky z čtyř rozměrné D-Vine a C-Vine kopule (vlevo dole). Levá část ukazuje příklad první úrovně. Panely převzaty z Klepáč a Hampel (2015).	44
Obr. 2 Simulace 1000 vzorků ze dvourozměrných kopula funkcí (Kendalovo tau = 0,9), těžké konce indikují vysokou horní nebo dolní závislost v této oblasti	63
Obr. 3 Výběr ze simulace trajektorií vývoje hodnoty aktiva pro 1 společnost (trajektorie pod červenou hranicí (v čase 1) značí default)	65
Obr. 4 Blokové schéma zpracování dat (převzato z Holčík (2012))	66
Obr. 5 Dendrogram společností (R- rizikové a N-nerizikové) přes Wardovu metodu (převzato z Klepáč a Kamarýtová (2015))	68
Obr. 6 Vizualizace podpůrných vektorů (body na hranicích jsou podpůrné vektory, vzdálenost od hranice znázorňují šipky) v tomto případě pomocí lineárního jádra (převzato z James (2013))	69
Obr. 7 Vizualizace podpůrných vektorů s polynomiálním jádrem 3. řádu (převzato z James (2013))	70
Obr. 8 Znázornění klasifikace pro dvě skupiny pomocí nelineárního RBF jádra (převzato z James (2013))	71
Obr. 9 Kontingenční/chybová tabulka (převzato z Fawcet (2004))	73
Obr. 10 Dendrogram založený na účetních datech (rok 2011)	77
Obr. 11 Dendrogram založený na účetních datech (rok 2012)	78
Obr. 12 Dendrogram založený na účetních datech (rok 2013)	78
Obr. 13 Dendrogram založený na účetních datech (rok 2014)	79
Obr. 14 Odhad volatility pro období 2008 až 2015 (30 společností, popis zkratk společnosti je obsažen v Tab. 50)	87

Obr. 15	Odhad volatilitý pro období 2008 až 2015 (30 společností, popis zkratek společností je obsažen v Tab. 50)	88
Obr. 16	Odhad volatilitý pro období 2008 až 2015 (30 společností, popis zkratek společností je obsažen v Tab. 50)	88
Obr. 17	Dendrogram založený na pravděpodobnostech z Mertonova modelu (rok 2014)	96
Obr. 18	Dendrogram založený na pravděpodobnostech z Mertonova D-Vine kopula modelu (rok 2014)	96
Obr. 19	Dendrogram založený na pravděpodobnostech z Mertonova modelu (rok 2013)	98
Obr. 20	Dendrogram založený na pravděpodobnostech z Mertonova D-Vine kopula modelu (rok 2013)	98
Obr. 21	Dendrogram založený na pravděpodobnostech z Mertonova modelu (rok 2012)	100
Obr. 22	Dendrogram založený na pravděpodobnostech z Mertonova D-Vine kopula modelu (rok 2012)	100
Obr. 23	Schéma klasifikačního stromu (data z roku 2012)	105
Obr. 24	Schéma klasifikačního stromu (data z roku 2012)	106
Obr. 25	Schéma klasifikačního stromu (data z roku 2013)	107
Obr. 26	Schéma klasifikačního stromu (data z roku 2013)	108
Obr. 27	Schéma klasifikačního stromu (data z roku 2014)	109
Obr. 28	Schéma klasifikačního stromu (data z roku 2014)	110
Obr. 29	Dendrogram založený na anualizované volatilitě (rok 2013)	135
Obr. 30	Dendrogram založený na anualizované volatilitě (rok 2012)	135
Obr. 31	Dendrogram založený na anualizované volatilitě (rok 2011)	136
Obr. 32	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2011, 1. úroveň závislosti)	136
Obr. 33	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2011, 2. úroveň závislosti)	137

Obr. 34	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2011, 3. úroveň závislosti)	137
Obr. 35	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2012, 1. úroveň závislosti)	138
Obr. 36	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2012, 2. úroveň závislosti)	138
Obr. 37	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2012, 3. úroveň závislosti)	139
Obr. 38	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2013, 1. úroveň závislosti)	139
Obr. 39	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2013, 2. úroveň závislosti)	140
Obr. 40	Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2013, 3. úroveň závislosti)	140
Obr. 41	Dendrogram založený na pravděpodobnostech z Altmanova modelu (rok 2014)	141
Obr. 42	Dendrogram založený na pravděpodobnostech z Ohlsonova modelu (rok 2014)	141
Obr. 43	Dendrogram založený na pravděpodobnostech z Altmanova modelu (rok 2013)	142
Obr. 44	Dendrogram založený na pravděpodobnostech z Ohlsonova modelu (rok 2013)	142
Obr. 45	Dendrogram založený na pravděpodobnostech z Altmanova modelu (rok 2012)	143
Obr. 46	Dendrogram založený na pravděpodobnostech z Ohlsonova modelu (rok 2012)	143
Obr. 47	Dendrogram založený na pravděpodobnostech z Altmanova modelu (rok 2011)	144
Obr. 48	Dendrogram založený na pravděpodobnostech z Ohlsonova modelu (rok 2011)	144
Obr. 49	Stanovení počtu komponent pro dendrogram za data za rok 2011 (8 komponent)	160

Obr. 50	Stanovení počtu komponent pro dendrogram za data za rok 2012 (10 komponent)	161
Obr. 51	Stanovení počtu komponent pro dendrogram za data za rok 2013 (10 komponent)	161
Obr. 52	Stanovení počtu komponent pro dendrogram za data za rok 2014 (10 komponent)	161

Seznam tabulek

Tab. 1	Průměrné Z(EM) dle stupně ratingu	35
Tab. 2	Vybrané proměnné využívané ke klasifikaci uváděné v literatuře	56
Tab. 3	Dostupné Archimédovy kopule	61
Tab. 4	Dostupné eliptické kopule	62
Tab. 5	Použité proměnné	67
Tab. 6	Četnosti rizikových (R) a nerizikových (N) společností pro jednotlivé hodnotící kategorie v datovém setu pro každý ze sledovaných roků	76
Tab. 7	Kumulovaná variabilita datového souboru	76
Tab. 8	Základní průměrné statistické charakteristiky pravděpodobností finančních obtíží dle Altmanova a Ohlsonova modelu	79
Tab. 9	Základní průměrná statistická skóre dle Altmanova a Ohlsonova modelu	80
Tab. 10	Přiřazení rizikových značek u 20 nejlepších společností podle O-skóre nebo Z-skóre	81
Tab. 11	20 nejméně rizikových společností podle Altmanova modelu (rok 2012)	82
Tab. 12	20 nejméně rizikových společností podle Ohlsonova modelu (rok 2012)	82
Tab. 13	20 nejméně rizikových společností podle Altmanova modelu (rok 2013)	83
Tab. 14	20 nejméně rizikových společností podle Ohlsonova modelu (rok 2013)	83
Tab. 15	20 nejméně rizikových společností podle Altmanova modelu (rok 2014)	84

Tab. 16	20 nejméně rizikových společností podle Ohlsonova modelu (rok 2014)	85
Tab. 17	Základní průměrné statistické charakteristiky pro denní výnosy	87
Tab. 18	Základní statistické charakteristiky anualizované volatility (v letech 2012 až 2014, 100% je rozptyl = 1)	89
Tab. 19	20 společností s nejvolatilnějšími akciemi a jejich vztah k rizikovým značkám v roce 2014	89
Tab. 20	20 společností s nejvolatilnějšími akciemi a jejich vztah k rizikovým značkám v roce 2013	90
Tab. 21	20 společností s nejvolatilnějšími akciemi a jejich vztah k rizikovým značkám v roce 2012	91
Tab. 22	Výsledky z odhadu kopula funkcí pro zvolené datové sety (četnosti typů kopulí při volbě)	93
Tab. 23	Statistiky Kendallova tau pro data	94
Tab. 24	Základní charakteristiky pravděpodobnosti defaultu	95
Tab. 25	Nejrizikovější společnosti (rok 2014)	97
Tab. 26	Nejrizikovější společnosti (rok 2013)	99
Tab. 27	Nejrizikovější společnosti (rok 2012)	101
Tab. 28	Pravděpodobnosti finančních obtíží účetních modelů v letech 2012 až 2014	102
Tab. 29	Pravděpodobnosti defaultu strukturálních modelů v letech 2012 až 2014	102
Tab. 30	Základní statistiky rizikových ukazatelů s dělením na rizikové a nerizikové společnosti (v roce 2014)	102
Tab. 31	Základní statistiky rizikových ukazatelů s dělením na rizikové a nerizikové společnosti (v roce 2013)	103
Tab. 32	Základní statistiky rizikových ukazatelů s dělením na rizikové a nerizikové společnosti (v roce 2012)	103
Tab. 33	Přesnost klasifikátorů pro běžnou likviditu	111

Tab. 34	Přesnost klasifikátorů pro zadluženost	111
Tab. 35	Základní statistické charakteristiky zvolených ukazatelů pro rok 2014	129
Tab. 36	Základní statistické charakteristiky zvolených ukazatelů pro rok 2013	129
Tab. 37	Základní statistické charakteristiky zvolených ukazatelů pro rok 2012	130
Tab. 38	Základní statistické charakteristiky zvolených ukazatelů pro rok 2011	131
Tab. 39	Složení dílčích komponent 2011	131
Tab. 40	Složení dílčích komponent 2012	132
Tab. 41	Složení dílčích komponent 2013	133
Tab. 42	Složení dílčích komponent 2014	133
Tab. 43	Vstupní údaje pro odhad rizika pro 2014 (v Kč)	145
Tab. 44	Vstupní údaje pro odhad rizika pro 2013 (v Kč)	147
Tab. 45	Vstupní údaje pro odhad rizika pro 2012 (v Kč)	149
Tab. 46	Pravděpodobnosti defaultu na základě Mertonova D-Vine kopula modelu pro všechny společnosti	152
Tab. 47	Dostupné proměnné z databáze Amadeus	153
Tab. 48	Výsledky odhadnuté pravděpodobnosti účetních modelů (zleva od r. 2011 do r. 2014)	155
Tab. 49	Hodnoty účetních modelů s vyznačením jejich pozice v rámci souboru: nadprůměrné (červeně) a podprůměrné hodnoty (zleva od r. 2011 do r. 2014)	158
Tab. 50	Značky společností a obor podnikání	162

1 Úvod a cíl práce

1.1 Úvod

Kreditní riziko je v důsledku doznívající finanční krize, zvyšujícího se zadlužení států i domácností jedním z nejdůležitějších druhů rizik. Jedná se o riziko, které vymezuje neočekávané změny v kreditní kvalitě protistrany nebo emitenta. Jinými slovy, kreditní je riziko pravděpodobnost změny hodnoty podniku způsobená tím, že protistrana nesplní svůj závazek. Jako takové je jedním z ústředních finančních pojmů posledních let. Kreditní kvalita společnosti odvozená od kreditního rizika společností ovlivňuje způsob získávání kapitálu, náklady na kapitál, rizikový kreditní spread – pokud není jisté, že společnost je schopná dostát svým závazkům. Finanční společnosti po celém světě podléhají různým druhům rizik, které na základní úrovni můžeme ohraničit ve formě rizik: operačních, tržních, likvidity, systematických a kreditních. V rámci norem BASEL II nebo BASEL III jsou banky nuceny vyvíjet interní ratingové systémy pro krytí a řízení svých kapitálových expozic ve vztahu k vlastnímu zadlužení. Kreditní riziko je také důležitým atributem v oblasti Solvency II u pojišťoven, jež své kapitálové prostředky ukládají do dlouhých cenných papírů, se kterými je spojené riziko úpadku společností. S tím a spolu s použitím kreditních derivátů je spojena rostoucí potřeba po modelování kreditního rizika za neustále sofistikovanějších výpočetních prostředků. To s sebou přináší i zvýšený zájem akademické obce o aplikaci moderních metod pro účely oceňování a měření kreditního rizika. Kromě pohledu finančních institucí můžeme pracovat i v rozměru kreditního rizika nefinančních společností, které čelí rizikům obdobným, avšak s částečně odlišnými předpoklady nebo aplikacemi. Lze jistě uvést, že z pohledu systému vyhodnocování rizika je žádoucí uvažovat jednak o velikost prostředků, pravděpodobnosti jejich navrácení (resp. úpadku dlužníka), míře jejich navrácení při defaultu a dalších faktorech, dopadu ztráty z jednotlivé entity na celé kreditní portfolio. V této práci nevycházíme přímo z pohledu bankovníctví, ani se nesnažíme o přímé vyčíslení možných ztrát v podobě cVaR nebo LGD, ale spíše chceme zachytit a dát do souvislosti různé modelové přístupy a vztahy v podmínkách ČR, kde se předpokládá nižší schopnost akciového trhu a aktuální ceny přenést informace o kreditní kvalitě, nebo budoucí profitabilitě společností.

Konkrétněji se náš pohled blíže zaměřuje na riziko defaultu podle výkladu používaného v bankovníctví, ale se zacílením na měření kreditního rizika podniku jako protistrany a hlubšího testování uplatnění strukturálních modelů v ČR a v dalších zemích Evropy, jako jednoho z nástrojů měření kreditní kvality společnosti, kte-

ré využívá sofistikovanější matematicko-statistické metody. Druhý vhodný pohled odpovídá pohledu hodnocení finančního zdraví v podnikové praxi, kdy obvyklé snahy vedou k testování přesnosti tzv. bankrotních modelů. Měření kreditních rizik tedy úzce souvisí s pravděpodobností, že protistrana dodrží kontraktační podmínky a výši potenciálních možných ztrát, pokud dojde k jejich porušení. Standardní modely měření kreditního rizika vycházejí z fundamentální analýzy založené primárně na účetních datech. Základ těchto modelů vychází z dřívějších prací: Altmana (1968), Beavera (1966) nebo Ohlsona (1980), kteří uvažují o vhodných rizikových faktorech z finanční analýzy, které determinují, zda je společnost ve stavu bankrotu nebo fázi stability. Strukturální modely naproti tomu využívají metody z oceňování finančních opcí, které vycházejí z původní práce Blacka, Scholese a Mertona. Strukturální přístupy nabízejí vysvětlení finanční stability na základě změn v kapitálové struktuře a tržní kapitalizace ve spojitém čase.

Další ústřední skupinou jsou modely redukované, které nemají tak silnou ekonomickou podstatu jako modely strukturální, kreditní událost je zde exogenní událostí, při přiřazování rizika vycházíme z cen rizikových dluhopisů a dat trhu kreditních derivátů. Lze říci, že pro aplikaci v praxi a obchodování s kreditními deriváty tyto modely nabízejí vhodnější nastavení.

Vývoj segmentu strukturálních i redukováných modelů vedl k dalšímu rozšíření využívaných metod. Pro nově vzniklou třídu modelů, která kombinuje obě předchozí skupiny, ale i modely účetní, se vžil název hybridní modely. Odlišností strukturálních modelů je zejména propojení kreditní události s firemními fundamenty, např. aktivy či kapitálovou strukturou. Tato vazba se projevuje závislostí např. pravděpodobnosti defaultu firmy či termínové struktury kreditních spreadů na hodnotě těchto fundamentů. Je tedy znám faktor, který ovlivňuje kreditní událost a ta proto není exogenní veličinou jako v případě redukováných modelů.

V rámci této práce tyto teorie rozvádíme a chceme otestovat, zda jsou využívané modelové předpoklady uplatnitelné v podmínkách ČR a zda existují rozdílné výsledky oproti vyspělejším trhům. Tedy, zda je vůbec opodstatněné využití strukturálních modelů rizika v dříve uvedené podobě i k hodnocení bonity společností. Při testování využíváme přístupy, které vycházejí z klasifikačních metod, kdy se snažíme klasifikovat společnosti rizikové nebo zbankrotované při využití proměnných ze strukturálních a bankrotních modelů.

V dizertační práci využíváme strukturální modely rizika jako přístupy k zachycení budoucího potenciálu k finančním obtížím společností z pohledu výraznějších změn ve finanční struktuře společnosti; tedy kreditní riziko je rovno riziku kreditní události, avšak tak jak plyne z hybridních modelů rizika – ve spojení s hlubším propojením na analýzu finančních ukazatelů.

Výsledky analýz doplňujeme o vlastní přístup založený na zachycení závislosti mezi akciemi společností na finančním trhu. Tyto přístupy ověřujeme na změně dalších podnikových ukazatelů. Protože chceme výsledky alespoň částečně ověřit a zobecnit, musíme vycházet z dat více společností a primárně mezi jedním méně vyspělých trhem (ČR) a trhy vyspělejšími, které představují společnosti z EU. V ČR nedošlo k bankrotu likvidní, veřejně obchodované společnosti, proto musíme vycházet z jemnějšího chápání rizikových modelů, a také jiných ukazatelů, jako je např. změna ratingu či výraznější zhoršení finanční situace (krizové scénáře v podobě určitého nastavení finančních ukazatelů).

Podobná studie v podmínkách ČR v posledních letech chybí, částečné zpracování na případu dvou firem pro širší spektrum strukturálních modelů lze nalézt např. u Míška (2006) nebo Peška (2007), který odvozoval vysvětlovací schopnosti Mertonova modelu oproti datům z ratingového hodnocení většího počtu českých společností.

V následujících pěti obsahově ohraničených kapitolách budou nejprve představeny bankrotní a strukturální modely rizika spolu s výsledky výzkumů, které se zabývaly jejich rozšířením. Tato část ozřejmí variabilitu oblasti modelování kreditního rizika zejména skrze hlubší pohled na provázání mezi kapitálovou strukturou společností a kreditní ukazatele společnosti, kdy vycházíme z teorie hybridních modelů rizika. Jejím cílem je poskytnout základní matematický i kvalitativní přehled o vztazích užívaných v popsáních modelech. Moderní oborová literatura využívá ukazatelů z bankrotní analýzy pro klasifikaci bankrotu pomocí pokročilých data miningových přístupů, kam můžeme řadit metodu podpůrných vektorů, na jejíž empirické testování se také zaměříme.

V části Materiál a metodika popisujeme dílčí kroky a metody, které vedou k řešení praktické části práce. Zaměřujeme se i na výzkumy a využitá řešení dalších autorů. Podáváme také detailní popis řešení modelových vztahů pro získání vstupních parametrů. Kapitola mimo jiné obsahuje i základní přehled metod, které využíváme při klasifikaci společností, které se řadí do data miningu nebo vícerozměrné statistiky: shluková analýza, metoda hlavních komponent (PCA) a metoda podpůrných vektorů (SVM), rozhodovací stromy, odhady kopula funkcí.

Finální výpočetní částí a hlavním přínosem práce je popis sestavení Merton-D-Vine kopula modelu k odhadu kreditního rizika¹ společnosti. V poslední kapitole praktické části práce budeme aplikovat vybrané modely na datech společností během let 2011 až 2014. Provádíme finanční analýzu rizika pomocí běžných modelů.

¹ V původním významu rizika defaultu, naším cílem je obecnější pojetí rizika. Proto tento pojem zastupuje celkovovou špatnou finanční situaci společnosti, resp. stav finanční krize a finančního ohrožení společnosti.

Dále se snažíme určit, jakým způsobem se promítlo kolísání akcií společností do vývoje jejich finančních ukazatelů. A zda vývoj trhu nebo z něho odvozené proměnné předznamenaly v určitých letech vývoj společnosti. Mimo to kalkulujeme kreditní ukazatele a na jejich základě klasifikujeme společnosti dle rizika (zadluženost, likvidita). Podobně je tomu přístupu za využití kopula funkce, pomocí které zachycujeme vývoj finančního trhu, a ze kterého na základě korelací mezi společnostmi na finančním trhu převádíme rizikovost do simulace pravděpodobnosti defaultu ve spojení se strukturálním Mertonovým modelem.

V závěrečné části práce shrnujeme výsledky práce, diskutujeme řešení s dostupnou literaturou ohledně přesnosti klasifikace a vyvozujeme závěry pro další zpracování.

1.2 Cíl práce

Hlavním cílem dizertační práce je na základě provedených kvantitativních analýz a modelování sestavit a otestovat výpočetní algoritmy pro klasifikaci krizových scénářů veřejně obchodovatelných společností, při využití kopula funkcí a strukturálních modelů rizika. Splnění hlavního cíle práce vyžaduje splnění jeho dílčích částí:

- Systematizovat nejvýznamnější proudy z teorie predikce finanční tísně podniku a kreditního rizika: blíže analyzovat účetní, strukturální modely a metody tzv. umělé inteligence. Využít pravděpodobnosti defaultu nebo bankrotu odvozené z modelování při klasifikaci krize společnosti.
- Rozšíření teorie o model transformující tržní riziko do podoby rizika kreditního za využití vícerozměrné D-Vine kopula funkce a Mertonova strukturálního modelu kreditního rizika.
- Srovnat pravděpodobnosti defaultu s výsledky vybraného strukturálního, jednoho odvozeného na základě kopula funkcí a dvou původních bankrotních modelů.
- Otestovat přístupy pro klasifikaci bankrotu a detekci krize jako stavu s delším průběhem v podmínkách ČR a EU pomocí metody SVM a rozhodovacích stromů. Srovnat jejich predikční schopnosti pomocí metod data miningu na různě specifikovaných datových souborech, v různém předstihu před defaultem.

1.3 Praktické přínosy

- Práce osvětlí, jaká je v evropském prostoru závislost mezi tržním rizikem na veřejně obchodovaném trhu a výstupech modelů kreditního rizika, spolu

s dříve uvedenými bankrotními modely – vyvození vztahu tržního a kreditního rizika pro konkrétní podnikatelské subjekty.

- Práce by měla poskytnout algoritmy pro automatizaci diagnostiky finanční situace společností obchodovaných na finančním trhu pro specifický vývoj akciových dat dané společnosti.
- Spojení metodických přístupů, které nebyly v podmínkách ČR využity či publikovány. Totéž se týká snahy odvodit model pro měření bankrotů, popř. zhoršení finanční situace českém a zahraničním finančním trhu. Struktura metodiky je v českém prostředí ojedinělá vzhledem k vytvoření hybridního modelu rizika a srovnání jeho výsledků s některými původními modely.
- Původní práce se zaměřují při testování kvality predikčních modelů na různé cíle jako je například detekce bankrotu nebo kalibrace tržních cen kreditních kontraktů. V této práci využíváme metody pro detekci různých stavů podnikových ukazatelů, tak abychom byli schopni využít a validovat využití vyspělých matematických modelů i v podmínkách České republiky, kde je nemožné zajistit tržní data běžná ve vyspělých zemích.
- Metodiku by mělo být možné přenést i na jiné veřejně obchodovatelné společnosti, které plní vstupní modelové předpoklady, v ČR i v zahraničí.

2 Základní pojmy

Vzhledem k záměru pracovat s různými výzkumnými směry pro hodnocení rizik je nutné na tomto místě nejprve ozřejmit důležité pojmy, které v práci často využijeme.

Data mining

Data mining nebo jinými slovy dolování dat zahrnuje širokou škálu algoritmů, které slouží ke zkoumání často rozsáhlého množství dat a objevování nových informací. Základní algoritmy, které využíváme, jsou: klasifikace, která rozděluje vstupní data do dvou nebo několika tříd, regrese odhaduje číselnou hodnotu výstupu podle vstupu a shlukování zařazuje objekty do skupin s podobnými vlastnostmi, typicky při učení bez učitele.

Typ dat

Data mohou být běžného typu, tj. kvantitativní (numerické – spojité, diskrétní a ve speciálním případě binární, logické, které nabývají dvou diskrétních hodnot, ale lze určit, která z nich znamená méně, která více a je možné s nimi provádět matematické operace); ordinální – typ kategoriální proměnné, její hodnoty ale lze vzájemně seřadit, je však nemožné či obtížné kvantifikovat jejich hodnoty (např. bolest zanedbatelná, malá, střední, velká, nesnesitelná); nominální – opět typ kategoriální proměnné, v tomto případě ale nelze jejich hodnoty seřadit podle velikosti. Speciálním typem nominální proměnné je tzv. dichotomická proměnná, která podobně jako proměnná binární či logická nabývá dvou hodnot, které se navzájem vylučují, ale v tomto případě nelze určit jejich velikost, např. pohlaví muž/žena.

Klasifikace

Klasifikací rozumíme rozdělení dané (konkrétní či teoretické) skupiny (množiny) objektů, jevů či procesů na konečný počet dílčích skupin (podmnožin), v nichž všechny objekty, jevy či procesy mají dostatečně podobné společné vlastnosti. Vlastnosti, podle nichž lze klasifikaci zadat či provádět, určují klasifikační kritéria. Objekty, které mají podobné vlastnosti, tvoří klasifikační třídu. Klasifikaci provádíme pomocí klasifikátoru, tj. funkcí, která zařazuje objekty do tříd. Pro sestavení modelu potřebujeme množinu bodů se správným popsáním (kategorické proměnné) – tréninkovou množinu. Klasifikace musí být úplná, každý předmět musí patřit do nějaké třídy a nemůže být současně ve dvou či více třídách. Formálně je klasifikátor modelem nebo funkcí. Po učení modelu můžeme automaticky predikovat kategorie pro další proměnné. Existuje mnoho druhů klasifikačních algoritmů, mezi

nejznámější patří binomický popř. multinomický regresní model rozhodovací stromy, metoda podpůrných vektorů, neuronové sítě apod.

Shlukování

Shlukování je úlohou dělení bodů do přirozených skupin zvaných shluky. Objekty ve stejném shluku, jsou si podobné, přičemž objekty, a patří do odlišného shluku, jsou co nejvíce odlišné. Shlukování je často využíváno v oborech, jako je umělá inteligence, rozpoznávání signálů, ekonomii, ekologii, psychiatrii nebo marketingu.

Prognostické metody ve financích

V rámci práce se blíže zaměříme na kvantitativní nebo jinými slovy objektivní metody. Aplikuje se zde statistická analýza dat z minulosti v různých časových pohledech. Prognostik či analytik s využitím historických dat identifikuje cestu k předpovědi a pomocí vhodného matematického modelu předpovídá hodnoty v budoucnosti. Kromě toho známe i metody kvalitativní (subjektivní), které se využívají v situacích, kdy nejsou data dostatečná, nebo nelze události kvantifikovat. Mezi zástupce těchto metod řadíme:

- individuální úsudek,
- naivní extrapolace,
- analogii a historickou analogii,
- Delfskou metodu.

Opce

Opce je derivátovým kontraktem mezi dvěma stranami, kde derivát je kontrakt, jehož hodnota je odvozená od určitého podkladového aktiva. Dává právo, nikoliv povinnost, koupit nebo prodat (kupní opce – call opce, prodejní opce – put opce) podkladové aktivum za předem stanovenou cenu ve stanovený čas. S opcí se váže tzv. opční právo, které umožňuje kupujícímu odstoupit od kontraktu, jestliže by podmínky obchodu pro něj nebyly výhodné. V případě, že by kupující opce chtěl v budoucnu pořídit aktivum (opce jako nástroj zajištění ceny), musí na počátku zaplatit za opci tzv. prémii.

Náhodná veličina

Nechť Ω je neprázdná množina a S je systém podmnožin množiny Ω takový, že:

- $\Omega \in S$
- Když $A \in S$, potom $A' \in S$
- Když $A_1, A_2, \dots \in S$, potom $\cup A_i \in S$

Potom S nazýváme jevové pole (σ -algebra) nad množinou Ω . Dvojici (Ω, S) nazýváme měřitelný prostor. Mějme měřitelný prostor (Ω, S) . Náhodná veličina je pak funkce $X: \Omega \rightarrow S$ taková, že pro každé $x \in R: \{\omega \in \Omega: X(\omega) < x\} \in S$.

Pravděpodobnost

Nechť Ω je neprázdná množina a S je systém podmnožin množiny Ω . Pod pravděpodobností budeme rozumět zobrazení $P: S \rightarrow R$ s těmito vlastnostmi:

- $P(\Omega) = 1$
- $P(A) > 0$ pro každé $A \in S$
- $P(\cup A_i) = \sum P(A_i)$

Trojici (Ω, S, P) pak nazýváme pravděpodobnostní prostor.

Časové řady

Časová řada je realizací stochastického procesu, kde „Stochastický proces je v čase uspořádaná řada náhodných veličin $\{X(s,t), s \in S, t \in T\}$, kde S je výběrový prostor a T je indexní řada. Pro každé $t \in T$ je $X(.,t)$ náhodná veličina definovaná na indexní řadě T , tj. uspořádaná řada čísel, z níž každé odpovídá jedné hodnotě indexní řady“ (Arlt a Arltová, 2007).

Kopule

Kumulativní distribuční funkci náhodného vektoru lze zobrazit v podobě jeho dílčích distribučních funkcí a kopula popisuje strukturu závislosti mezi těmito komponentami. Tyto metody lze zařadit do oblastí vícerozměrné statistiky a ekonometrie. Kopule byly poprvé v matematickém smyslu uvedeny Sklarem (1959) skrze tzv. Sklarův teorém.

3 Literární rešerše

Nejlepší obranou proti finančním potížím je finanční zdraví, které spočívá v uspokojivé finanční situaci. Je-li však značně oslabeno (např. provozními potížemi – vážnoucí odbyt, vysoké náklady), dostane se podnik do finanční tísně, která může přerůst ve finanční krizi a skončit úpadkem (Synek, 2007). Hlavním nástrojem, který by nás měl informovat o kondici podniku, je účetnictví a z něho vycházející finanční analýza, která má kromě svých základních funkcí za cíl identifikovat scénáře vedoucí k finančnímu zdraví firmy a kvalitnímu rozhodování managementu.

3.1 Krize, finanční tíseň a default podniku

Lze tvrdit, že výklad výrazu krize záleží na kontextu a oboru autorů. Základní výklad podle Websterova slovníku je takový, že krize je bod obratu, kde dochází ke zhoršení. Jinými slovy může jít o nestabilní období nebo stav, kdy může dojít obratem k velice špatnému výsledku. Nebo takové vymezení času, kdy něco dospělo do kritické fáze. Krize mají své členění zejména podle intenzity a stavu: rozsahu, dopadu, fáze, pravděpodobnosti, povahy (strategická, likvidity a indukované hospodářskými obtížemi), a lokalizace příčiny. Mnoho organizací dále prohlubuje definici krizí:

- Podle standardu PAS 200:2011 Crisis Management (2011) se jedná o abnormální, nestabilní a komplexní situace, které reprezentují ohrožení strategických cílů, reputace nebo existence organizace.
- NATO: Národní nebo mezinárodní situace kde je ohrožení priority, zájmu nebo cílů.
- Fink (2002): Nestabilní stav, ve kterém je nutné rozhodnout o změně.
- Pearson a Sommer (2011): Krize jsou událostmi, které ohrožují životaschopnost organizace.

Základní kvalitativní charakteristiky podnikových krizí:

- Neočekávané – krize jsou unikátní a překvapivé události způsobené neadekvátním plánováním nebo v důsledky události, které překračují schopnosti organizace.

- Proměnlivé – krize ztělesňují intenzivní dynamické ohrožení, které má potenciál prioritu zvolených cílů společnosti a tím vytvořit nežádoucí výstupy pro samotnou organizaci a další zájmové skupiny.
- Urgentnost – krize vyžaduje rychlou reakci, která není časově určena organizací, společnost je nucena jednat. Důsledky z prodlení v jednání mohou vést až k likvidaci společnosti.
- Nejistota – důsledky rozhodnutí na nekompletních informacích vedou k nejistotě. Nemusí být zjevné, zda proti krizové kroky vedou až nápravě situace nebo spíše uškodí.
- Medializace – informace o krizovém stavu společnosti se nemusejí zakládat na pravdě, v moderním světě je jejich přenos rychlou záležitostí.
- Komplexnost – krize jsou většinou projevem více spojených událostí, vztahy více zájmových skupin. Reakce ze strany vedení by tomu měly odpovídat.

S krizí se spojuje krizový management, který je užíván k popisu způsobu, jakým organizace zvládají krizi. Jednotlivé výklady pojmu se liší stejně jako u krize, v závislosti na oboru. PAS 200:2011 Crisis Management neposkytuje přesnou definici. Ale vykládá krizový management jako proces, který připravuje organizaci na krize, řešení krize a ozdravení se z krize. NATO poskytuje definici zaměřenou na ozbrojené konflikty, jedná se o koordinované akce k rozpuštění krize, prevence jejich eskalace pro přechod do ozbrojeného konfliktu. Také se jedná o okamžitou odpověď na krizi. Fink (2002) uvádí, že se jedná o umění odebrání většiny rizika a nejistoty, aby organizace získala více kontroly nad svojí budoucností. Od vedení se očekává kritické rozhodování a určení směru při těch nejnáročnějších událostech. Podle Coombse (2011) jde o soubor faktorů navržených k boji s krizí a omezení škod.

Kromě krize známe i pojem bankrot a pojem finanční tíseň, který je obtížněji uchopitelný než bankrot. Podle Karlese a Prakashe (1987) je bankrot procesem, který začíná finančními obtížemi a končí právními kroky. To umožňuje bankrot lépe specifikovat a objektivně klasifikovat než v případě finanční tísně nebo krize podniku – to jsou pojmy do jisté míry subjektivní a závislé na zvyklostech odvětví, resp. hodnotách finančních ukazatelů. Moderní studie proto definují bankrot převážně z právního hlediska, dle Balcaen a Ooghe (2004). Tento přístup se vyskytuje také ve studiích Altmana (1986) nebo Ohlsona (1980).

Chan a Chen (1991) popisuje firmy ve finanční tísně tak, že ztratily tržní hodnotu, protože mají nízký výkon, neefektivní produkci, problém s cash flow a vysokým stupněm zadlužení. Obvykle ztratily významné tržní postavení, protože jejich ceny jsou více citlivé ke změnám ekonomiky, proto mají obtíže při přežití obtíž-

ných ekonomických podmínek. To s sebou přirozeně přináší zvýšené náklady na financování v důsledku objektivního zvýšení rizika. Podle dřívější práce Fitzpatricka (1932) existuje pět stupňů, které vedou k firemnímu bankrotu:

- Inkubace – postupný vývoj ukazatelů.
- Finanční ohrožení – management zjistí problémy.
- Finanční insolvence – společnost není schopna zajistit dodatečné financování.
- Celková insolvence – závazky překročí fyzickou hodnotu aktiv.
- Potvrzená insolvence – legální kroky vedoucí k ochraně věřitelů.

Karels and Prakash (1987) zmiňují například zápornou hodnotu aktiv, neschopnost splatit závazky, přečerpání bankovních účtů, odmítnutí vyplatit dividendu. Problémy nastávají při praktické aplikaci, zatímco dichotomie při hodnocení rizika obvykle vedla k využití diskriminační analýzy, realita je složitější, protože společnosti a jejich finanční situace podléhají více scénářům než jen bankrot/přežití, jak je obvykle zpracováváno v studiích o užití bankrotních modelů. Výhodnější a variabilnější hodnocení poskytují modely založené na tržních hodnotách dluhopisů nebo kreditních swapů nebo ratingu – teoreticky lépe reflektují skutečnost. To jsou přístupy, které se používají při dostupnosti dostatečně podrobných dat. U strukturálních modelů rizika hovoříme o pojmu default, který dle literatury můžeme popsat těmito kreditními událostmi (tři první body značí default):

- nesplacení závazku,
- odmítnutí splatit závazek,
- bankrot,
- změna kreditního ratingu,
- restrukturalizace firmy.

V rámci této práce se chceme zaměřit na události, které předznamenávají default, najít určité vzorce v chování společností, vývoje jejich firemních akcií a jejich výkazech. Některé z výše uvedených skutečností je obtížné přesně klasifikovat, proto volíme vzhledem k dostupným časovým okamžikům takové metody, které dokáží popsat výraznější zhoršení finanční stability společnosti dle různých metod nebo jejich kombinací. Tedy svým způsobem hledáme okolnosti, které vedly skrze krizi až do defaultu.

3.1.1 Příčiny krize

Rais (2007) řadí mezi nejčastější příčiny podnikových krizí ve vyspělých zemích následující:

- chaotické řízení,
- neochota ke změně způsobu řízení v nových podmínkách,
- nevhodná a chybná rozhodnutí spojená se slabou znalostí trhu,
- neúměrné firemní výdaje nekorespondující s vývojem tržeb,
- nesourodý informační systém,
- nedostatečná kvalifikace podnikového managementu,
- nedostatečné fungování kontrolního a plánovacího systému podniku,
- ukvapenou tržní expanzi,
- konjunkturální vlivy a změny na trhu,
- silné vazby na dodavatele nebo odběratele,
- nedostatek vlastního kapitálu,
- investování zisku mimo podnik,
- nízká motivace zaměstnanců,
- nesoulad mezi správními a řídicími orgány a neshoda v jejich zájmech a cílech,
- přeúvěrování, nedostatečné vlastní finanční zdroje, nedostupnost úvěrových zdrojů a vysoké bankovní úroky,
- chybějící strategie, vysoký podíl operativní činnosti vrcholového managementu, neznalost nebo malá znalost a využívání strategického řízení a metod řízení vůbec,
- osobní neschopnost managementu na jedné straně a přílišný optimismus a přehnaná sebedůvěra na straně druhé; vyhýbání se riziku nebo naopak přijímání velkého rizika (neznalost míry rizika), obavy ze zásadních změn,
- platební neschopnost odběratelů a špatná platební morálka,
- nedostatky ve finančním řízení, především cash flow,
- neuplatňování marketingového řízení spojené s nedostatečnou konkurenceschopností výrobků a služeb a neznalostí postavení výrobního portfolia na trhu a fáze životního cyklu vlastních výrobků a odvětví,
- neúměrné investice, často dražší než plánované nebo směřované do nesprávných podnikových aktivit,

- vysoká vnitropodniková režia a nízka produktivita práce včetně nadbytečného počtu zaměstnanců,
- nedostatky ve výkaznictví a evidenci promítající se do neznalosti vlastních nákladů a tím chybné cenové kalkulace vyúsťující do špatného výrobního portfolia.

3.1.2 Fáze a příznaky krize

Krize mají obvykle dlouhodobější průběh, než je například havárie. Potenciál krize existuje v podniku nepřetržitě, mnohdy po dobu několika let. Poté zůstává otázkou, zda management dokáže tuto latentní fázi krize rozpoznat a změnit chování nebo procesy. V následné akutní fázi pak společnost obvykle nemá dostatečnou hotovost (Rais, 2007), což může mít fatální následky. Jestliže se nepodaří tuto fázi zvrátit, společnost rozprodává svá aktiva. Přesněji lze podle Raise (2007) krizi v úvodní fázi rozpoznat dle níže uvedených jevů:

- zhoršování podnikového klimatu, pokles iniciativy a angažovanosti pracovníků,
- problémy v komunikaci mezi pracovníky,
- pokles inovační schopnosti podniku a růst rutinního jednání,
- nejasné stanovení pravomocí a úkolů,
- zvyšování centralizace rozhodování,
- prosazování autoritativního nebo liberálního stylu vedení,
- špatná spolupráce mezi podnikovými útvary,
- podniková kultura neodpovídá potřebám a cílům podniku,
- snižování kvality vzdělávání zaměstnanců,
- nezájem o návrhy pracovníků,
- zvyšující se počet porad a prodlužování jejich délky.

V akutní fázi již můžeme identifikovat kvantifikovatelné příznaky (Rais, 2007):

- klesá vlastní jmění,
- rostou finanční náklady,
- klesá rentabilita kapitálu,
- klesají tržby,
- narůstají cizí zdroje,

- omezují se investiční výdaje,
- roste objem závazků po lhůtě splatnosti,
- zvyšuje se podíl krátkodobých cizích zdrojů na jejich celkovém objemu,
- stagnuje, snižuje se nebo kolísá odbyt,
- snižují se průměrné ceny,
- klesá počet zákazníků,
- rostou zásoby rozpracované výroby,
- roste fluktuace zaměstnanců,
- zvyšují se prostoje, klesá produktivita práce.

3.2 Geneze modelů kreditního rizika

Většina z podnikových predikčních modelů se řadí mezi kvantitativní modely a vstupy jsou výsledky technické finanční analýzy. Určitou míru subjektivity můžeme u těchto modelů spatřovat při stanovení váhových koeficientů u jednotlivých poměrových ukazatelů nebo u výběru samotných ukazatelů, které jsou v modelu zastoupeny. Prognózu budoucího vývoje firem se zabývalo mnoho odborníků, kteří sestavili velké množství více či méně úspěšných predikčních modelů, u kterých je klíčovou oblastí přesné vyčíslení pravděpodobnosti defaultu nebo alespoň určení, na základě kterých proměnných k tomu dojde.

Jak bylo nastíněno, tato problematika má hlubší teoretické pozadí. Zdefaultování dlužníka, ze kterého vychází popsané modely, předpokládá neschopnost dostat svým závazkům. Otázkou zůstává, zda lze tyto modely využít i prakticky pro zhodnocení postupného zhoršování finančních situace dlužníka, zda lze predikovat default s větším předstihem. V práci vycházíme ze třetí ústřední skupiny kreditních modelů: účetních, strukturálních, hybridních ve smyslu propojení dvou předchozích. Další skupinou (redukovanými modely) se nebudeme zabývat, zejména z důvodu nedostupných dat pro české společnosti.

Přístupy založené na účetních datech, jako například úvodní práce Fitzpatricka, Beavera (jednorozměrné modely) ze 60. let, Altmana (diskrimanční analýza), Ohlsona (model logistické regrese nebo také jen logit model), Zmijewského (probit model) a dalších autorů například s neuronovými sítěmi, metodou podpůrných vektorů a ostatními klasifikačními algoritmy, vycházejí obvykle z dat, díky kterým získáme pouze pohled nasměřovaný na minulost. Predikce defaultu nebo bankrotu je ale ze své podstaty dopředu nasměřovaná operace, modely vycházejí z předpokladu, že minulost dokáže vystihnout současnost nebo dokonce budoucnost. Úskalí

účetních modelů podle některých empirických studií z hlediska teoretické správnosti a robustnosti:

- Předpoklad bipolárně závislých proměnných – diskriminační analýza předpokládá, že závislé proměnné jsou dichotomické. Díky tomu se při predikci podnikového selhání předpokládá, že soubory krachujících a nekrachujících firem jsou dobře definovány a zřetelně vzájemně odděleny. V praxi ale toto striktní rozdělení společností do dvou skupin není možné. Proto je použití dichotomické závislé proměnné v rozporu s realitou. Problémem je také definice selhání, kdy každý autor volí jiné kritérium pro rozdělení společností na krachující a prosperující.
- Výběr proměnných pramení často z modelů, které byly populární v literatuře.
- Metodika výběru souboru dat vzorových firem. Ve většině klasických modelů je jejich konstrukce založena na datech nenáhodně vybraných firem a výsledky proto nemohou být zobecňovány. Existují však autoři, jako např. Zmijewski (1984), kteří uvádějí, že použití nenáhodných vzorků firem nemá výrazný vliv na celkovou míru přesnosti.
- Nestabilita dat vstupních souborů – použití např. diskriminační analýzy v kontextu predikce bankrotu vyžaduje, aby vztahy mezi proměnnými byly stabilní v čase. To ale v realitě nefunguje. Problém datové nestability finančních ukazatelů je největší u firem, které se nacházejí před bankrotem.
- Využití sloučených základních vzorků – ve většině studií zaměřených na modely predikce firemního selhání je základní soubor dat smíšený obsahuje data o společnostech krachujících v různých letech. Výsledné modely tedy neuvažují základní ekonomické události a vycházejí z různých makroekonomických podmínek. Na druhou stranu, pokud by byl model založen na datech z velmi omezeného časového období, snižuje se tím jeho vypovídací schopnost při aplikaci na jiná (následná) časová období.
- Účetní závěrka jako zdroj dat – je nutné předpokládat, že roční účetní závěrky poskytují pravdivý a čestný pohled na finanční situaci podniku.

Účetním modelům je dále vyčítána neexistence hlubší ekonomické podstaty. Lze dokonce říci, že se jedná o souboj efektivností použití ukazatelů, pro ten který teoretický pohled. Další nevýhoda plyne z nízké periodicity finančních výkazů a od toho zpožděných predikcí. Také pohled na aktiva a jejich tržní hodnotu je zde zkreslen, historické ocenění může způsobit nerealistické zvýšení pravděpodobnosti defaultu. To je spojené s neschopností měřit volatilitu hodnoty podnikových aktiv, což je klíčové při tom, zda společnost v realitě dokáže splatit své závazky. Spo-

lečnosti se stejnými účetními výkazy, ale odlišnou volatilitou aktiv tedy budou mít odlišné hodnoty pravděpodobnosti defaultu. Mimo to mohou být vykazovaná data upravena nebo manipulována ze strany managementu společnosti, např. kvůli zvýšení informační asymetrie.

Standardní účetní nebo skóringové modely poskytují pravděpodobnosti defaultu pouze po jistých statistických transformacích. V původní podobě historické účetní přístupy neberou v potaz tržní vývoj společností, což může být jejich výrazným nedostatkem.

Kritika těchto základních modelů vedla další autory jako je Merton (1974) a jeho následovníky k rozvoji třídy modelů strukturálních, které využívají také data z finančního trhu, která by měla obsahovat všechny potřebné informace o stavu podniku, tzn. včetně účetních veličin. Pro tuto podtřídu modelů se vžil spolu s redukovanými přístupy název tržní modely.

Lze říci, že tato třída metod se snaží objektivně vysvětlit kauzalitu mezi proměnnými, které ovlivní, zda firma zdefaultuje nebo přežije. V případě modelů účetních statisticky hodnotíme, které účetní proměnné nebo finanční ukazatele klasifikovaly společnosti finančně zdravé a nemocné nebo nakažené. Pro praktické aplikace v zahraničí nebo praxi ratingových agentur se tyto strukturální modely osvědčily, ačkoliv jejich aplikace je složitější než u modelů účetních, částečně i z důvodu obtížného získávání vstupních dat.

Kromě teoretických rozdílů mezi účetními a strukturálními modely, existují i rozdíly mezi jejich empirickou přesností při odhadu defaultu nebo bankrotu. Proto zde nejprve uvádíme několik vybraných prací, které vypovídají o empirickém srovnání obou skupin modelů.

Demirovic a Thomas (2007) studovali vztah mezi kreditními ratingy a různými účetními proměnnými, včetně z tržních dat odvozené Mertonovy vzdálenosti do defaultu na datech společností z Velké Británie (pro interval v letech 1990 až 2002). Účetní hodnoty mají vyšší vysvětlovací schopnost než kreditní ukazatel plynoucí z teorie KMV.

Hillegeist a kol. (2002) ukazují ve své srovnávací studii na množině dat amerických společností od roku 1979 do roku 1997, který obsahoval 65 960 nezbankrotovaných společností a 516 zbankrotovaných, že Mertonův model, při více různých nastaveních parametrů poskytuje pravděpodobnosti defaultu, které poskytují větší informační hodnotu při modelování pravděpodobnosti bankrotu přes regresní hazardní modely, než poskytují pravděpodobnosti získané přes Altmanovo Z-skóre nebo Ohlsonovo O-skóre. Korelace mezi hodnotou Z-skóre a O-skóre a stavem bankrotu je taktéž nižší v případě indikátorů odvozených z Mertonova modelu.

Agarwal a kol. (2008) zmiňují, že Altmanův model dle Altmana (1968) i Mertonův model poskytují srovnatelné výsledky. Vycházejí přitom z výzkumu provedeného na datech nefinančních společností z Velké Británie mezi lety 1985 a 2001, avšak dodávají, že tržní/strukturální (v tomto případě Mertonův model) i účetní modely poskytují unikátní informace, avšak mají své technické nedostatky. U Mertonova modelu jsou to zejména rigidní teoretické předpoklady a u modelů účetních jde o chybějící teoretickou oporu. Výhodným přístupem by mohlo být jejich spojení do hybridní podoby modelu. Autoři dále uvádějí, že účetní modely jsou vytvořené na základě velkého počtu proměnných a konkrétního vzorku dat – je tedy obtížné zobecnit jejich výsledky nad rámec použitého poměru mezi počtem zdefaultovaných a zdravých společností.

Mezi další studie patří práce Agarwala a Tafflera (2007), kteří uvádějí, že modely, které obsahují tržní proměnné, poskytují vyšší informační hodnotu, než modely čistě účetní. Při analýze autoři vycházeli z australských dat 1197 nefinančních společností od roku 1999 do roku 2007 a regresních hazardních modelů. V případě, že byla do modelu s účetními proměnnými přiřazena data tržní, tak některé účetní proměnné ztratily svoji statistickou významnost.

Balcaen a Ooghe (2004) uvádějí, že je jen těžko uvěřitelné, že indikátory bankrotů lze dokonale popsat pouze z účetních ukazatelů. Je patrné, že tyto ukazatele nemohou zachytit všechny podstatné události, které se odehrávají na trzích, proto je vhodné doplnit prognostické modely o proměnné, které tyto tržní události zahrnují.

Rees (1995) uvádí, že tržní ceny mohou být užitečným ukazatelem rizika pravděpodobnosti defaultu – jelikož tržní ceny reflektují očekávání o budoucích peněžních tocích.

Podle Hillegeista a kol. (2004) ceny akcií obsahují informace o možném vývoji společností, protože doplňují známé informace z účetnictví o další zdroje. Další výhodou je možnost rozšířit účetní údaje o čtenější pozorování z finančního trhu a fakt, že lze pomocí nich hodnotit i volatilitu.

V průběhu času bylo provedeno mnoho testování přesnosti klasifikace bankrotu na datech. Existují čtyři převažující datové zdroje, které se využívají pro testování kvality predikce: zjištěná data bankrotů, cen obligací – jejich rozpětí, spready kreditních swapů (CDS), změny ratingů. Je proto zjevné, že testování predikční schopnosti jednotlivých modelů proti sobě navzájem se může zdát diskutabilní, protože se jen obtížně dosahuje objektivní validnosti výsledků nebo jejich replikace.

Jak tedy vidíme, obě skupiny mají své výhody i nevýhody, na které ve studiích naráží mnoho autorů. Pravděpodobně nejlépe se jeví možné spojení tříd modelů a využívání výhod, které každá ze skupin nabízí. Bohužel zatím neexistuje mnoho

prací, které by spojovaly proměnné získané ze strukturálních modelů s aplikací moderních data-miningových metod, které nabízejí flexibilní přístup k problémům. V následujících částech si popíšeme technickou povahu vybraných účetních, strukturálních a na metodě SVM založených modelů.

3.2.1 Účetní modely

Tyto modely pracují s myšlenkou, že určitá kombinace finančních ukazatelů nebo jednorozměrné poměrové ukazatele mohou v předstihu indikovat finanční problémy nebo dokonce bankrot společností. V dalších částech uvedeme pouze vybrané přístupy, které měly nejzávažnější dopad na vývoj tohoto směru predikce finanční situace podniku, tj. modely Altmana (1968, 1977, 2006) a Ohlsona (1980). Novodobé práce, které využívají účetní data, vycházejí z data miningových přístupů, kterými se v podobě algoritmu podpůrných vektorů budeme detailněji zabývat v části empirických studií. Lze tvrdit, že v moderní podobě aplikací není určující jaké proměnné využít, ale spíše na základě jaké metody učení modely pracují a jaké je množství dat. Jak bylo uvedeno, účetní modely neposkytují natolik silnou teoretickou oporu jako modely strukturální.

3.2.1.1 Altmanův model

Altmanův model (Altmanův index či Z-skóre) je nejen v České republice velice oblíbená metoda, pravděpodobně díky svému poměrně jednoduchému výpočtu (Kislingerová a Hnilica, 2008). Altman použil ke klasifikaci bankrotu vícerozměrnou diskriminační metodu, což je přímá statistická metoda spočívající v třídění pozorovaných objektů do dvou nebo více definovaných skupin podle určitých charakteristik (Růčková, 2010). Tento přístup byl delší dobu využíván jako referenční ze strany mnoha autorů. Na základě této metody byla vyvozena rovnice, která je součtem hodnot pěti běžných poměrových ukazatelů, kterým jsou přiřazeny jednotlivé váhy (Růčková, 2010). Jak bylo uvedeno dříve, před Altmanem (1968) byla predikce rizika bankrotu ve své podstatě jednorozměrná, jako např. u Beavera (1966). Na těchto základech Altman rozšířil standardní poměrovou analýzu kombinací dílčích ukazatelů. Do datového souboru zařadil 66 amerických výrobních společností, z nichž bylo 33 zbankrotovaných a 33, kterých přežilo. Celková přesnost klasifikace zde byla 95%. Původní model z roku 1968 měl tvar pro společnosti s veřejně obchodovatelnými akciemi:

$$Z = 1,2WC/TA + 1,4RE/TA + 3,3EBIT/TA + 0,6MVE/D + 1S/TA, \quad (1)$$

kde

- WC/TA je poměr čistého pracovního kapitálu a celkových aktiv,
- RE/TA poměr nerozděleného zisku a celkových aktiv,
- $EBIT/TA$ poměr $EBIT$ a celkových aktiv,
- MVE/D poměr tržní hodnoty vlastního kapitálu a účetní hodnoty cizích zdrojů,
- S/TA poměr tržeb a celkových aktiv.

Dále interpretujeme jednotlivé proměnné pro objasnění jejich podstaty.

WC/TA. Rozdíl mezi oběžnými aktivy a krátkodobými závazky reprezentuje pracovní kapitál. Oběžná aktiva zde představují hotovost, prostředky na účtech a zásoby v případě, že se jedná o prostředky, které budou přeměny na peníze během obchodního období. Pozitivní hodnota pracovního kapitálu indikuje, že společnost je schopná dostát svým závazkům. Poměr pracovního kapitálu a celkových aktiv je běžným indikátorem užívaným ve výzkumných studiích. Pracovní kapitál se definuje jako rozdíl mezi oběžnými aktivy a krátkodobými závazky. Společnost, která operuje s negativními provozními výsledky, má v této podobě snižující se objem oběžných aktiv. Mezi další poměrové ukazatele se v této souvislosti řadí běžná likvidita, avšak jejich přínos byl shledán jako omezený.

RE/TA. Nerozdělené zisky zahrnují objem reinvestovaných prostředků získaných ze zisku nebo ztráty. Tato položka kumulované profitability je dobrým indikátorem a váhou pro hodnocení přežití společnosti. Lze očekávat, že mladé společnosti nevytvořili během svého života dostatečně vysoké nerozdělené zisky narozdíl od starších společností. Odpůrci tohoto modelu toto zmiňují ve své kritice, ale v reálném světě platí, že i 50 % společností bankrotuje v prvních letech života. Také platí, že poměr RE/TA poukazuje na páku společností, vyšší RE vzhledem k TA poukazuje na nižší využití dluhového financování.

EBIT/TA. Ukazatel měří produktivitu firemních aktiv, nezávislou na daních nebo finanční páce, což odpovídá skutečnosti, kdy přežití společnosti závisí na schopnosti generovat zisk z aktiv. I v tomto modelu platí, že úpadek nastává v případě, kdy celkové závazky převýší ocenění firemních aktiv.

MVE/D. Vlastní kapitál je měřen jako kombinace tržní hodnoty všech emitovaných akcií, kdy závazky jsou dlouhodobé i krátkodobé. Metrika ukazuje, jak výrazně firemní aktiv a klesají na hodnotě, než závazky překonají hodnotu aktiv a společnost zbankrotuje. Tento poměr a povaha hodnoty vlastního kapitálu tedy přibližuje společnost k tržnímu ocenění, což je teoreticky vhodnější, než čistě účetní hodnoty. Podoba ukazatele byla později změněna na účetní hodnoty pro modelování rizika u společností bez veřejně obchodovaných akcií. Jak již bylo zmíněno, strukturální modely rizika využívají také tržní hodnoty akcií k odvození tržní hodnoty aktiv.

S/TA. Ukazatel umožňuje měřit schopnost společnosti generovat tržby pomocí aktiv. Můžeme říct, že se jedná o ukazatel schopnosti managementu čelit konkurenčním tlakům při srovnání s ostatními společnostmi. Některé další odvozené modely tento ukazatel neobsahují, zejména kvůli vysoké variabilitě diskriminační schopnosti mezi jednotlivými odvětvími.

Pokud je hodnota Z vyšší jak 2,99, můžeme o firmě říci, že má uspokojivou finanční situaci. Pokud index klesne pod 1,81, má firma velmi silné finanční problémy. Pokud se firma nachází v rozmezí od 1,81 do 2,99, hovoříme o nevyhraněné finanční situaci, tzv. šedé zóně (Knápková, 2010). V analytické části práce budeme počítat s touto verzí. Pokud však společnosti nemají veřejně obchodovatelné akcie, nastává problém s ukazatelem X_4 , resp. s výpočtem tržní hodnoty vlastního kapitálu. Z toho důvodu se může provést odhad této hodnoty jako pětinasobek ročního cash flow, nebo lze použít pro výpočet účetní hodnotu vlastního kapitálu.

3.2.1.2 Altmanův ZETA model

U společností bez obchodovaných akcií Altman (1977) upravil model, pro který se vžilo označení ZETA, došlo zde ke změně ve čtvrtém ukazateli, kdy tržní vyjádření vlastního kapitálu přešlo do účetního vyjádření

$$ZETA = 0,717WC/TA + 0,847RE/TA + 3,107EBIT/TA + 0,42AVE/D + 0,99S/TA, (2)$$

kde

- WC/TA je poměr čistého pracovního kapitálu a celkových aktiv,
- RE/TA poměr nerozděleného zisku a celkových aktiv,
- $EBIT/TA$ poměr $EBIT$ a celkových aktiv,
- AVE/D poměr účetní hodnoty vlastního kapitálu a účetní hodnoty cizích zdrojů,
- S/TA poměr tržeb a celkových aktiv.

Kromě změny hodnoty se změnil i stupeň pro klasifikaci. Pokud je hodnota ZETA vyšší než 2,9, můžeme o firmě říci, že má uspokojivou finanční situaci – nachází se v bezpečné zóně. Pokud index klesne pod 1,23, má firma velmi silné finanční problémy. Pokud se firma nachází v rozmezí od 1,23 do 2,9, hovoříme o nevyhraněné finanční situaci, tzv. šedé zóně. V tomto případě byl využit vzorek 106 výrobních a obchodních společností za roky 1969 až 1975, klasifikační schopnost modelu čítá 92 % jeden rok před bankrotem, s větším odstupem pak výrazněji klesá. Autoři využili 53 společností, které zbankrotovaly a 58 finančně zdravých společností. Pro ČR je výhodnější užít právě verzi ZETA, protože většina společností ne-

má likvidní obchodovatelné akcie, proto lze jen obtížně usuzovat, že reflektují správně reálnou hodnotu společnosti.

3.2.1.3 Altmanův model pro rozvíjející se trhy

Další Altmanův model slouží k posouzení společností z tzv. rozvojových trhů nebo nevýrobních společností. Tvar modelu je zde podle Altmana (2006)

$$Z(EM) = 3,25 + 6,5WC/TA + 3,26RE/TA + 6,72EBIT/TA + 1,05VE/D, \quad (3)$$

kde

- WC/TA je poměr čistého pracovního kapitálu a celkových aktiv,
- RE/TA poměr nerozděleného zisku a celkových aktiv,
- $EBIT/TA$ poměr $EBIT$ a celkových aktiv,
- VE/D poměr tržní hodnoty vlastního kapitálu a účetní hodnoty cizích zdrojů,
- S/TA poměr tržeb a celkových aktiv.
- Konstantní člen s hodnotou 3,25 odpovídá mediánu Z-skóre pro zbankrotované společnosti podle modelu Altmana a Hotchkissové (2006).

Znovu zde došlo ke změně hranice bankrotu, blíže popsané v Tabulce 1, která poslouží i jako vysvětlení spojení s ratingem – autor využil k odvození korespondujících hranic ratingu data 750 dluhopisů z trhu USA.

Tab. 1 Průměrné Z(EM) dle stupně ratingu

Hodnota Z(EM)	Rating v USA	Zóna
>8,15	AAA	Bezpečná
7,6–8,15	AA+	Bezpečná
7,3–7,6	AA	Bezpečná
7,0–7,3	AA-	Bezpečná
6,85–7,0	A+	Bezpečná
6,65–6,85	A	Bezpečná
6,4–6,65	A-	Bezpečná
6,25–6,4	BBB+	Bezpečná
5,85–6,25	BBB	Bezpečná
5,65–5,85	BBB-	Šedá
5,25–5,65	BB+	Šedá
4,95–5,25	BB	Šedá

4,75–4,95	BB-	Šedá
4,5–4,75	B+	Finanční tíseň
4,15–4,5	B	Finanční tíseň
3,75–4,15	B-	Finanční tíseň
3,2–3,75	CCC+	Finanční tíseň
2,5–3,2	CCC	Finanční tíseň
1,75–2,5	CCC-	Finanční tíseň
<1,75	D	Bankrot

Zdroj: Převzato z Altman (2005).

3.2.2 Ohlsonův model

Ohlson (1980) analyzoval pomocí logit modelu z let 1970 až 1976, přesněji 105 zbankrotovaných a 2058 nebankrotovaných výrobních společností z USA. Přesnost modelu byla ve své době 96 %, resp. 85 % pro testovací množinu. Konkrétně autor využíval 9 proměnných:

$$O = -1,32 - 0,407 \ln(TA_t) + 6,03 \frac{TL_t}{TA_t} - 1,43 \frac{WC_t}{TA_t} + 0,757 \frac{CL_t}{CA_t} - 1,72X - 2,37 \frac{NI_t}{TA_t} - 1,83 \frac{FFO_t}{TL_t} + 0,285Y - 0,521 \frac{NI_t - NI_{t-1}}{|NI_t| + |NI_{t-1}|}, \quad (4)$$

kde TA jsou celková aktiva, TL jsou celkové závazky, WC pracovní kapitál, CL krátkodobé závazky, CA oběžná aktiva, dummy proměnná $X = 1$ pokud $TL > TA$, 0 v opačném případě, NI je čistý příjem, FFO jsou prostředky z finančních operací. Y nabývá hodnoty 1, jestliže byla čistá realizovaná ztráta v posledních dvou letech, v jiném případě hodnota 0. Ohlson stanovil dělicí mez mezi společnostmi zbankrotovanou a zdravou na úrovni 0,38. Platí, že čím vyšší hodnota O-skóre, tím vyšší pravděpodobnost bankrotu. Přepočítáváme na pravděpodobnost default pomocí vzorce

$$PD = \frac{e^{0-\text{skóre}}}{1+e^{0-\text{skóre}}}. \quad (5)$$

Celkové skóre indikující pravděpodobnost defaultu se tedy nachází mezi čísly 0 a 1, pokud je nižší, než 0,5 tak společnost nebankrotuje a naopak. U logit modelu vyjadřuje výsledná hodnota pravděpodobnost úpadku. Tuto vlastnost je jistě možné považovat za přednost modelu, kdy přímo z hodnoty funkce vyjádříme míru rizika (pravděpodobnost) úpadku sledovaného podniku. Koeficienty modelu je možné chápat jako vyjádření významnosti jednotlivých proměnných při predikci úpadku. Neboli vyjádření velikosti jejich vlivu na odhadovanou pravděpodobnost úpadku.

3.2.3 Strukturální modely

Tento typ modelů se pokouší zachytit objektivní podnikové skutečnosti, dynamiku uvnitř společnosti – primárně odvozené z tržní hodnoty aktiv a díky modelu odvodit rizikové ukazatele. Strukturální modely jsou založeny na moderní finanční teorii, přesněji na opční teorii. Není proto překvapením, že prvopočátky strukturálních modelů jsou spjaty se jmény jako Myron Scholes, Fisher Black a Robert Merton. Tito autoři přispěli významným způsobem k teorii oceňování opcí a rovněž položili i základy strukturálních modelů kreditního rizika. Cílem těchto modelů je určit okamžik defaultu pomocí vývoje firemních strukturálních proměnných, jako jsou firemní aktiva a dluh společnosti.

Indikátorem defaultu je potom pokles hodnot aktiva pod defaultní bariéru, tzn. aktiva nepokryjí splatnou velikost závazků. Výstupem modelu jsou pravděpodobnosti, které mohou předznamenat blížící se kreditní událost. Strukturální modely kreditního rizika se nezaměřují na projekce firemního cash flow či odhad budoucího zisku. Veřejně obchodovatelné akcie následně zohledňují nejaktuálnější informace související s firemními fundamenty. Prostřednictvím nich generované tržní hodnoty aktiv budou tyto informace obsahovat. Tržní cena aktiv tedy zahrnuje budoucí šance firmy a rovněž i relevantní informace o odvětví a ekonomice, ve které firma působí. Volatilita tržní ceny aktiv potom zohledňuje obchodní riziko firmy a riziko příslušného odvětví. Předpokládá se, že zmíněné projekce a odhady jsou již zohledněny v tržních cenách firemních akcií.

V případě, že ceny firemních aktiv nejsou pozorovatelné (což je ve většině případů), předpokládá se alespoň znalost tržních cen firemních akcií, popř. tržních cen některých závazků (např. dluhopisů). Pokud nejsou k dispozici ani tato data, je použitelnost strukturálních modelů kreditního rizika velice omezená. Účetní hodnota aktiv totiž není zpravidla srovnatelná s tržní cenou aktiv, protože zohledňuje pouze historickou pořizovací cenu, výši odpisů a opravné položky. Nezachycuje tedy budoucí výnosy související s držetím aktiva a firemní příležitosti, které jsou obvykle již zahrnuty v tržních cenách. Při jakékoliv změně v očekávaných ohledně firemní budoucnosti budou právě akcie nejvíce reagovat na tyto změny.

Vycházíme z toho, že default lze v praxi jen obtížně predikovat u jedné společnosti. Jak víme, je reálnější klasifikovat společnosti pomocí hromadného datového souboru. Proto využíváme pravděpodobnostní metriky resp. jejich variabilitu v čase na základě náhodného charakteru strukturálních podnikových veličin. Validace a kalibrace modelů poté v praxi probíhá na tržních datech (tržní cena dluhopisů, kreditních derivátů), výstupů ratingových hodnocení nebo datech o realizovaných bankrotech společností.

Znalost pravděpodobnosti defaultu následně poté finančním institucím umožňuje odhadnout kreditní spread (tj. přírážku za riziko), který bude kompenzovat věřiteli možnou majetkovou újmu spojenou s podstupovaným rizikem defaultu. Pravděpodobnost defaultu zpravidla roste s rostoucím časovým horizontem, tj. s delší dobou do splatnosti příslušného dluhopisu či závazku. Obvykle platí, že čím déle společnost podniká, tím více existuje situací, kdy riskuje svoje postavení a stabilitu. Z hlediska životního cyklu podniku společnost podléhá životním fázím, ke kterým přirozeně náleží i krize, které trh reflektuje v rámci cen kreditních kontraktů apod.

Pestrá geneze strukturálních modelů zahrnuje přístupy, které proti základnímu Mertonovu modelu (default až při splatnosti dluhopisu, konstantní úrokové sazby, bezkupónový dluhopis) rozšiřují modely o potenciál předčasného defaultu (First Passage Time modely, safety covenants doložky) jako u Blacka a Coxe (1976), stochastické úrokové sazby u Longstaffa a Schwartz (1996), složitější kapitálovou strukturu u Geskeho (1977), kde jsou závazky společnosti složené z více kupónových dluhopisů a priority věřitelů apod. Bližší popis dalších modelů lze nalézt v knize Cariboniové a Schoutense (2007).

V další části si blíže představíme pouze základní Mertonův model a empirické testování modelů uvedeme i pro další modely. Ačkoliv je následně nebudeme přímo aplikovat na datech. Pro nás tyto slouží modely pro získání proměnných do dalších komplexnějších modelů – tedy lze očekávat jen jejich velice omezenou schopnost predikce rizika osamoceně, resp. nejsme schopni jejich samostatnou predikční sílu dostatečně kvalitně ověřit na základě dostupných dat, viz Klepáč (2014), zejména pro tuzemská data. I empirické studie a výstupy dalších autorů jsou v mnoha případech ohledně strukturálních modelů rizika značně rozporuplné.

3.2.3.1 Mertonův model

Základním modelem, pomocí jehož byly vytvořeny modely složitější, je Mertonův model, který v základu vychází z přístupu Blacka a Scholese k oceňování opcí. Proto v základu podléhá těmto předpokladům:

- Neexistují transakční náklady, daně ani problémy s dělitelností aktiv.
- Existuje dostatečné množství investorů se stejnou úrovní bohatství a všichni z nich věří, že mohou zakoupit nebo prodat aktiva za stanovenou tržní cenu.
- Existuje trh pro půjčování a vypůjčování peněžních prostředků při stejné úrokové sazbě.
- Neexistuje omezení na prodej aktiv.

- Platí Modiglianiho-Millerův teorém, který stanovuje, že hodnota společnosti je nezávislá na její kapitálové struktuře.
- Výnosová křivka je plochá a známá s určitostí.
- Hodnota firemních aktiv se řídí v čase difúzním procesem.

Myšlenka modelu pracuje s aktivy společnosti, která jsou tvořena vlastním kapitálem a závazky. Přesněji je hodnota aktiv rovna hodnotě vlastního kapitálu $E = \{E_t, 0 < t < T\}$ a hodnotě bezkupónového dluhopisu $z^t = \{z^t, 0 < t < T\}$ s maturitou T a nominální hodnotou. Matematicky pak značíme

$$V_t = E_t + z_t^T, \quad (6)$$

kde E_t je hodnota vlastního kapitálu a z_t^T hodnota bezkupónového dluhopisu. Velké a středně velké společnosti jsou zde financovány emisí akcií a dluhopisů. Default nastává pouze v čase splatnosti dluhopisu. A to pouze tehdy jestliže hodnoty aktiv nestačí k pokrytí jmenovité hodnoty dluhu. V tomto případě držitelé dluhopisu převezmou kontrolu nad společností (obdrží likvidační hodnotu společnosti bez likvidačních nákladů) a držitelé kapitálu (akcií) neobdrží nic – hodnota jejich akcií je nulová. V opačném případě, tedy když hodnota aktiv pokryje závazek, tak akcionáři obdrží částku ve výši $V_t - L$. Tyto předpoklady o charakteru aktiv společnosti nám umožní pohlížet na aktiva jako na evropskou kupní opci. Blíže značené následovně (7)

$$E_t = \max(V_t - L, 0) = \begin{cases} V_t - L, & \text{když } V_t > L \text{ (ne default).} \\ 0, & \text{když } V_t < L \text{ (default).} \end{cases}$$

Protože vycházíme z Blackova-Scholesova modelu, tak se hodnota aktiv řídí geometrickým Brownovým pohybem, dle Cariboniové a Schoutense (2007)

$$dV_t = \mu V_t dt + \sigma V_t dW_t, V_0 > 0, \quad (8)$$

kde $W = \{W_t, t > 0\}$ je standardní Brownův pohyb, μ proces střední hodnoty, a $\sigma > 0$ je parametr volatility, V značí hodnotu aktiv. Výnosy aktiv jsou řízeny vztahem

$$\log V_t - \log V_0 = \left(\mu - \frac{\sigma^2}{2} \right) t + \sigma W_t, \quad (9)$$

který je generován normálním rozdělením, $N((\mu - \sigma^2/2)t, \sigma^2 t)$. Tedy finální hodnoty V mají log-normální rozdělení. Hodnota firemních aktiv se v průběhu času mění v závislosti na tom, jak trh zohledňuje budoucí ziskové příležitosti firmy. Tyto ziskové příležitosti mají určitý stupeň rizika a mohou být popsány stochastickým procesem. Mertonův model tedy využíváme k odhadu pravděpodobnosti defaultu v čase T , pro čas t uvádíme

$$P_t[\tau - T] = N[-d_2^p], \quad (10)$$

kde $d_2^p = (\sigma\sqrt{T-t})^{-1} (\log(\frac{A}{L}) + (\mu - \frac{\sigma^2}{2})(T-t))$ a N je kumulovanou distribuční funkcí standardizovaného normálního rozdělení. Skrze parciálně diferenciální rovnici modelujeme vztah hodnoty vlastní kapitálu jako call opce

$$S_t = V_t N(d_1) - e^{-r(T-t)} LN(d_2), \quad (11)$$

kde

$$d_1 = \frac{\ln\frac{A_t}{L} + (r + \frac{\sigma^2}{2})(T-t)}{\sigma\sqrt{T-t}}, \quad (12)$$

a

$$d_2 = \frac{\ln\frac{A_t}{L} + (r - \frac{\sigma^2}{2})(T-t)}{\sigma\sqrt{T-t}}, \quad (13)$$

kde funkce d jsou distribuční funkce normálního rozdělení, hodnota r udává bezrizikovou sazbu, L je nominální hodnota dluhopisu, d_1 slouží jako metrika, že hodnota aktiv skončí pod hodnotou L , d_2 slouží pro vyjádření opačného scénáře. Pro doplnění ještě uvedeme hodnotu rizikového dluhopisu, který je primární veličinou při analýze a z něho odvozeného kreditního rozpětí

$$D(t, T) = \exp(-(r + s(t, T))(T-t))L, \quad (14)$$

$$s(t, T) = \frac{\ln L - \ln D(t, T)}{T-t} - r, \quad (15)$$

kde s je kreditní rozpětí a D je hodnota rizikového dluhopisu v čase t , r je znovu hodnota bezrizikové úrokové sazby, L nominální hodnota dluhopisu. Matematické odvození je blíže uvedeno například v Míšek (2006). Protože nelze v běžném prostředí pozorovat tržní hodnotu firemních aktiv, musíme si vypomoci vztahy mezi jednotlivými rovnicemi a hodnotou obchodovaných akcií, které by měly teoreticky zobrazovat situaci podniku. Jestliže jsou tyto předpoklady oprávněné, můžeme využít metodu uvedenou v Jones, Mason a Rosenfeld (1984), při níž využíváme aktuální tržní hodnoty akcií a její volatility. Z odvození vztahů získáváme srovnání složek, ve kterých je obsažena volatilita aktiv a akcií

$$\sigma_s S_t = \frac{\delta S_t}{\delta t} \sigma V_t. \quad (16)$$

Hodnotu V_t získáme řešením soustavy nelineárních rovnic, při předpokladu, že vývoj akcií je řízený stejným procesem jako vývoj firemních aktiv

$$S_t = V_t N(d_1) - e^{-r(T-t)} LN(d_2), \quad (17)$$

$$\sigma_s = N(d_1) \frac{V_t}{S_t} \sigma. \quad (18)$$

Ze dvou získaných proměnných dopočteme tržní hodnoty aktiv i hodnoty jejich volatility. Úskalí přístupu spočívá v citlivosti na výši páky, výsledky platí jen dočasně. Pokud bude páka růst, výsledky, nadhodnocují výši rizika a naopak, viz Bohn a Crosbie (2003). Základní Mertonův model je startovním bodem pro hlubší analýzu rizika, jeho hlavní nedostatky přitom spočívají ve skutečnostech:

- Default společnosti nastává pouze v okamžiku splatnosti dluhopisu, bez ohledu na předchozí vývoj aktiva.
- Kapitálová struktura společností je jistě komplikovanější, než v tomto přístupu. Další modely, např. Geskeho (1977) upravují model do podoby dluhopisu s kupónovou platbou, tzn. že default může nastat v okamžicích plateb. Další rozšíření poskytuje model Longstafa a Schwartz (1995), která uvolňuje předpoklad o statické hodnotě úrokových sazeb.
- Je nesprávné soudit, že hodnota aktiv společnosti je obchodovatelná, ve skutečnosti tento parametr ani nelze objektivně pozorovat.
- Úrokové sazby jsou zcela jistě náhodné.
- Nestacionární struktura dluhu, která vede k ukončení obchodních operací ve fixním datu, kdy také musí dojít k jeho urovnání.
- Poslední modelové omezení, které uvedeme, může být predikovatelnost defaultu, kdy přesnost odhadu default se zvyšuje až s plynoucím časem, zpřesňování odhadu, tedy default není zcela náhodným jevem – řešením je dle Cariboniové a Schoutense (2006) zavedení skokového procesu, jak uvedli Cox a Black (1976).

3.2.4 Měření závislosti kreditního rizika

V práci využíváme vlastní přístup měření závislosti mezi rizikem u společností, který vyplývá ze strukturálních modelů rizika a zobecnění vícerozměrných Lévyho procesů, které jsou obvykle využívány jako řídicí procesy modelů ve financích. V oboru existuje jen několik málo prací, které by se zabývaly detailní analýzou predikční schopnosti vícerozměrných strukturálních procesů.

Hull a kol. (2006) a Overbeck and Schmidt (2005) zkoumali vícerozměrné rozšíření Blackova-Coxova modelu, speciálně model, ve kterém se aktiva společnosti řídí geometrickým Brownovým pohybem

$$dV_t^i = \mu^i V_t dt + \sigma_i V_t dW_t^i, \quad (19)$$

kde W^i značí korelované Brownovy pohyby. Lévyho procesy, mezi které patří i Brownův pohyb, jsou základním kamenem několika vícerozměrných přístupů, které publikovali Luciano a Schoutens (2006). Jejich kalibrace na datech je ale zřídka, jak dokládá studie Baxtera (2007), který aplikuje vícerozměrné Lévyho modely aktiv na datech kreditních spreadů. Dalším technickým rozšířením byla aplikace vícerozměrných kopula funkcí při modelování kreditního rizika, bohužel pro nás převážně se zaměřením na redukované modely. Odlišné přístupy se využívají v bankovní praxi, jako např. v metodice CreditMetrics, které nahlíží na problém korelace podnikových aktiv z perspektivy řízení portfolia úvěrů nebo závislosti mezi pravděpodobnostmi defaultů. Avšak toto směřování není předmětem této práce. V další části si představíme, kopula funkce, jako nástroj modelování závislosti, pro které základní přehled poskytuje Nelsen (1996).

3.2.4.1 Korelace a kopula funkce

Intenzita závislosti je v případě kopula funkcí i v tomto případě vyjádřena skrze pořadový korelační koeficient: obvykle buď Kendallovo tau nebo Spearmanova rho. Hodnoty těchto korelačních koeficientů dosahují hodnot -1 až 1 , jak je obvyklé u lineární korelace, která však není z teoretického i praktického hlediska vhodná pro měření závislosti mezi distribučními funkcemi s non-normálním rozdělením, resp. nelineární vztahy mezi daty. Výhoda pořadových korelačních koeficientů spočívá v tom, že jsou tzv. nezávislá na typu rozdělení, vycházejí z toho, že měří pořadí bodů v distribuci – tzv. monotónní závislost, nikoliv lineární odvozenou přímo z původních dat. Lineární korelační koeficient vyjadřuje sílu intenzity závislosti v celém datovém souboru, ale neposkytuje bližší náhled na polohu závislosti v rámci distribuční funkce.

Nevýhody pořadových korelačních koeficientů spočívají zejména v tom, že jsou jejich hodnoty obtížně reprodukovatelné nebo jen málo intuitivně uchopitelné pro různé datové soubory, z části proto, že ignorují kauzální vztahy mezi dvěma distribucemi. Důležitým pojmem je zde kopula funkce, která využívá pořadových korelačních koeficientů, díky čemuž můžeme exponovat při měření rizika konkrétní části distribučních funkcí, např. v oblasti extrémních poloh distribucí. Kopula funkce je sestavena při subjektivním hodnocení o marginálních distribučních funk-

cích. Kopule, které můžeme popsat následovně $C(u_1, u_2, \dots, u_n)$ je definovaná jako kumulativní distribuční funkce pro vícerozměrný vektor při $[0,1]^n$ a uniformních marginálních distribucích. Kopule je definovaná jako

$$C(u_1, u_2, \dots, u_n) = P(U_1 < u_1, \dots, U_n < u_n), \quad (20)$$

kde (U_1, U_2, \dots, U_n) je korespondující vícerozměrný vektor. Marginální distribuční funkce mohou být zvoleny jako takové přes transformaci $U_i = F_i(x_i)$. Rovnice (20) ukazuje, že každá vícerozměrná distribuční funkce může být psána ve formě jejich marginálních distribučních funkcí pomocí kopule. Spojitá distribuční funkce je definována jako

$$f(x_1, x_2, \dots, x_n) = f_1(x_1) f_2(x_2) \dots f_n(x_n) c[F_1(x_1), F_2(x_2), \dots, F_n(x_n)], \quad (21)$$

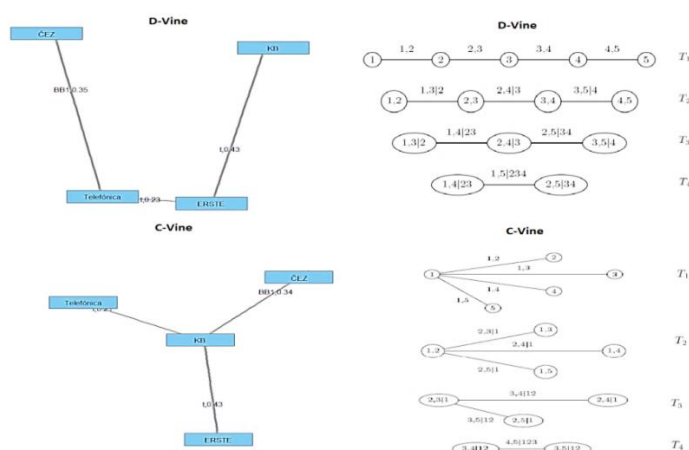
kde hustota C_i je dána vztahem

$$c(u_1, u_2, \dots, u_n) = \frac{\partial^n c(u_1, u_2, \dots, u_n)}{\partial u_1 \partial u_2 \dots \partial u_n}. \quad (22)$$

Druh kopule je zvolen, tak aby co nejlépe zachytil asymetrii v korelační struktuře, např. u aktiv nebo u finančních derivátů. Využití kopula funkcí může být problematické pro vícerozměrná data. K tomuto účelu byly vytvořené tzv. párové kopule. Jedním z těchto typů jsou, v práci využívané D-Vine kopule, jejichž hustotu můžeme psát jako výstup $N(N-1)/2$ párových kopulí

$$C_{D-Vine}(u; \emptyset) = \prod_{i=2}^N f(u_i | u_{i-1}, \dots, u_1) = \prod_{i=2}^N \prod_{j=1}^{i-1} c_{i,j}(u_{i|j}, u_{j|i-1}; \emptyset_{i,j}), \quad (23)$$

kde vektor parametrů $\emptyset \{ \emptyset_{i,j}; i = 2, \dots, N, j < i \}$ a $u_{j|i-1}$ jsou distribuční funkce U_i a U_j . Vine kopule jsou flexibilní třídy n -rozměrných závislostních modelů, kdy využíváme dvou rozměrné kopule jako stavební prvky. Aas a kol. (2009) popsali statistické metody pro odhad C-Vine kopulí a D-Vine kopulí. U C-Vine kopulí jsme schopni vytvořit vícevrstvou strukturu mezi jednou ústřední proměnnou a dalšími okolními proměnnými, tedy mohou být přínosné při modelování vztahu akciového tržního indexu a jednotlivých akcií. D-Vine kopule naproti tomu užíváme k modelování vnitřní struktury bez výběru ústřední (řídící) proměnné, tedy můžeme modelovat vztah v rámci jednoho portfolia. Vztahy je možné znázornit jako na Obr. 1.



Obr. 1 Příklady D-Vine a C-Vine stromu pro pět proměnných, na levé straně jsou vzorky z čtyř rozměrné D-Vine a C-Vine kopule (vlevo dole). Levá část ukazuje příklad první úrovně. Panely převzaty z Klepáč a Hampel (2015).

Obvykle aplikace tohoto typu kopulí můžeme nalézt v různých oborech finančního světa – nejčastěji se jedná odhad metrik VaR nebo cVaR ve spojení s modely GARCH, viz Klepáč a Hampel (2015) pro česká data finančního trhu. Prvotní práce o uplatnění Vine kopulí jsou Aas kol. (2009), Bedford and Cooke (2002), Joe (1996), Min and Czado (2010).

Pro nás zásadní práce Kortekaase (2013) poskytuje metodu, jak modelovat cenu opcí pomocí vícerozměrného modelu GARCH s aktivy, která se řídí Vine kopula GARCH modelem. Barbanová a Di Persio (2014) využívají model D-Vine kopula při oceňování portfolia složeného ze čtyř aktiv. Na základě konceptu výzkumu těchto prací budeme rozvíjet naši práci tím, že využijeme kopula funkci pro modelování inovací původního Brownova pohybu, na základě vytvoření simulační procedury pro měření pravděpodobnosti defaultu. Původní návrh metod užitých v těchto pracích vytvořil Duan (1995), který vytvořil známou proceduru pro oceňování opcí s řídicím procesem typu GARCH.

3.3 Empirické testování metod pro měření kreditního rizika a bankrotu

Původní bankrotní studie vycházely zejména z dat bankrotů, které využívají i moderní data miningové přístupy při klasifikaci různých podnikových stavů. Modely strukturální vycházely při testování přesnosti z odhadu indukovaných cen dluhopisů a tvaru nebo přesnosti odhadu jejich spreadu. Časem se přístup změnil na testování přesnosti odhadu CDS spreadů, které lépe zachycují čisté riziko defaultu bez dalších rizik nebo vlivu daní. Testování také probíhalo, hlavně pro účely ratingu, na

datech změn ratingu společností, resp. zde vypovídací schopnosti kreditních modelů.

Moderní hybridní přístupy využívají i kombinace strukturálních – tržních a účetních modelů, které testují na výše popsaných datech. Vzhledem k četnosti studií přiblížíme pouze výsledky vybraných studií, které jsou z našeho pohledu zásadní. Není možné ani užitečné podávat bližší přehled o každé z dostupných studií, protože se zabýváme zejména klasifikací na základě metody podpurných vektorů. U této metody blíže popíšeme dřívější výsledky, často se souvislostí na více-rozměrné statistické nebo data miningové metody, jejichž výsledky jsme pomocí studie Azize a Dara (2004) zobecnili pro přesnost klasifikace, která je pro nás primární.

Ačkoliv první studie o finančním zdraví společností, které využívají zejména jednorozměrné ukazatele, byly publikovány již ve třicátých letech minulého století, budeme se zabývat až pracemi od roku 1960. Publikované práce se podle Azize a Dara (2004) liší zejména počtem proměnných a metodami, kterými je provedena klasifikace bankrotu:

- Statistické jako je vícerozměrná diskriminační analýza (od 1970 dále), probit (1984), logit (1980) nebo CUSUM a odhady vícerozměrných VAR modelů. Obecně lze tvrdit, že tyto metody měly v průměru přesnost klasifikace 85 %.
- Výrazně nižší přesnost mají jednorozměrné metody – pouze okolo 75 %. V průměru tedy méně komplexní metody dosahovaly horších výsledků.
- Umělá inteligence nebo data mining: neuronové sítě (od 1990 dále), genetické algoritmy, a další klasifikační modely jako například metoda podpurných vektorů (od 2000 dále). Přesnost klasifikace zde je podle autorů průměrně okolo 90 %.
- Teoretické: strukturální modely rizika, hloubkové/expertní rozbory rozvah. Tyto modely mají přesnost okolo 91 % při určení bankrotu, avšak počet těchto studií je ve studii Azize a Dara (2004) pouze marginální, resp. studie založené na bankrotních datech obvykle nepracují s těmito teoretickými modely.

Nástup nových metod postupně vytěsňuje metody starší s tím, jak neustále roste přesnost při klasifikaci a technická dostupnost při aplikaci skrze různá výpočetní prostředí. V dalších částech se budeme zabývat metodou podpurných vektorů a rozhodovacími stromy, které lze řadit mezi metody umělé inteligence a data miningu, jež se dobře osvědčily i při predikci bankrotu.

3.3.1 Vybrané studie o využití algoritmu podpůrných vektorů a rozhodovacích stromů k predikci bankrotu

Metoda SVM, kterou vytvořil Vapnik (1995), dokázala získat popularitu díky mnoha výhodným vlastnostem a obstojným výsledkům. Jedná se o jednu z posledních metod, které se využívají úspěšně pro zachycení nelineárních a nemonotónních vztahů mezi finančními ukazateli a pravděpodobností defaultu.

Min a Lee (2005) testovali přesnost na datovém setu 1888 společností, při využití klasifikace pomocí neuronových sítí, diskriminační analýzy a logitu spolu se SVM s jádrem RBF. Posledním zmíněným přístupem, dosáhli na testovacím souboru složeném z 20 %, původních dat přesnosti 83 %. To bylo nejvíce proti ostatním alternativám. Vícerozměrná diskriminační analýza poskytla výsledky podobné jako logistická regrese (okolo 79 %). Autoři dospěli k názoru, že volba jádra u SVM závisí zejména na specifickém problému a datech: je obtížné předem určit správné nastavení modelu čistě na základě znalosti problému.

Ding, Song a Zen (2008) navrhují model predikce finanční tísně aplikací SVM. Výkonnost modelu je srovnána s konvenčními statistickými metodami (MDA, logit) a s neuronovými sítěmi, při jejichž použití autoři poukazují na problém přetrénování, a dále na obtížné stanovení všech parametrů sítě. Data tvoří celkem 250 vzorů vyvážených mezi přeživší a upadlé čínské firmy v období 2001–2004 s rozdělením 50:50 do tréninkového a testovacího souboru a s transformací vstupů do intervalu $(-1, 1)$. Predikce je založena na 11 finančních ukazatelích. Prediktivní výkon je měřen MSE (Mean Square Error) a klasifikační přesností s použitím křížové validace. Navržený model dosáhl ve srovnání s ostatními přístupy nejvyššího prediktivního výkonu, konkrétně klasifikační přesnosti 83 % na testovacím setu a s 10 % úrovní významnosti překonal srovnávací modely, jejichž přesnost se mezi sebou významně neliší.

Autoři Niknya, Darabi a Vakili (2013) hodnotí modely pro predikci finanční tísně pomocí SVM, vícerozměrné diskriminační analýzy a logistické regrese, pro společnosti z Teheránské burzy cenných papírů mezi lety 2007 a 2013. K tomu využívali ukazatele aktivity, profitability a přepočty na akcii a dělení dat na tréninková a testovací set, kde bylo 112 společností ve finanční tísně a 548 společností zdravých. Z jejich zjištění plyne, že SVM model má nejvyšší klasifikační schopnost (93 %), logistická regrese měla přesnost 85 % a metoda MDA nejnižší přesnost (82 %).

Shin, Lee a Kim (2005) aplikují SVM současně s třívrstvou neuronovou sítí při predikci bankrotu. Využívají celkově 2230 datových údajů korejských výrobních společností (v rozmezí 1996 až 1999) v základu s poměrem 50:50 mezi zbankrotovanými a finančně zdravými společnostmi. Využívali snížení počtu proměnných

skrze krokovou proceduru využívanou u MDA a t-test nezávislosti, čímž dospěli k finálním 10 proměnným z počátečních 250 ukazatelů. Z testování plyne, že využití SVM je výhodnější pro menší tréninkový set (okolo 50 společností), což neplatí u neuronových sítí (řádově stovky společností), kde je navíc obtížné najít optimální parametry. Celková přesnost při srovnání na různě velkých datových vzorcích byla mezi 80–90 % pro tréninkový soubor dat. U neuronových sítí byla přesnost ve srovnatelných případech o 10 % nižší.

Pro data bankrotů 250 veřejně obchodovaných čínských společností využil Dong a kol. (2008) metodu SVM a další metody (neuronové sítě, logistickou regresi a diskriminační analýzu) pro predikci bankrotu. Z těchto výsledků vyplynul jako nejvýhodnější model SVM s RBF jádrem. Přesnost klasifikace přes SVM byla 95,2 % a 83,2 % na testovacím souboru. Metoda neuronových sítí poskytla nejhorší výsledky, na testovacím souboru 76 %. Autoři uvádějí, že pro tento typ studií je analyzovaný počet společností příliš nízký a argumentují i tím, že čínská ekonomika není natolik rozvinutá oproti zemím z předchozích studií.

Huang a kol. (2004) využili zejména metodu SVM a neuronových sítí k predikci amerických a tchajwanských dluhopisů podle stupně ratingu, podle všech dostupných finančních ukazatelů i podle ukazatelů exponovaných ve finanční literatuře. Tyto vybrané ukazatele mají lepší výsledky než při zahrnutí všech dostupných dat. Z celkově čtyř modelů metoda SVM převýšila i metodu neuronových sítí. Jsou použity dva datové soubory: 25 tchajwanských bankovních institucí z let 1998–2002 a 36 komerčních bank z USA za období 1991–2000. Výsledky jsou hodnoceny podle přesností, obě metody dosáhly přesnosti klasifikace okolo 80 %, doplňkově byla zvolena i logistická regrese, která měla přesnost okolo 75 %. Studie se dále zabývá analýzou vlivu vstupních proměnných na výslednou klasifikaci a rozdílem při výběru proměnných pomocí ANOVA testu.

Mezi další prominentní metody predikce bankrotu patří rozhodovací stromy (existují četné poddruhy jako CART algoritmus vytvořený Breimanem a Cutlerem (1993) nebo C4.5 (Quinlan, 1993)).

Li, Sun a Wu (2010) poukazují na aplikovatelnost metody RS v oblasti predikce firemních úpadků a srovnávají její přesnost proti metodám, které zahrnovaly MDA, logit, kNN, a SVM. Další výzkumy využívaly ke zvýšení přesnosti predikce, kde Lin a McClean (2001) využívali MDA, logit, DT a NN tzv. ensemble metody. Konkrétně využili data 106 zbankrotovaných společností a 690 nebankrotovaných společností pro tréninkovou množinu a 48 zbankrotovaných a 289 nebankrotovaných společností pro validační set. Autoři dospěli k tomu, že metoda rozhodovacích stromů poskytuje lepší výsledky než MDA a logit. Mezi další studie o rozhodovacích stromech můžeme zařadit např. práce Gepp, Kumar a Bhatta-

charya (2010); Kim, Soo a Upneja (2014), dále pak Li, Sun a Wu (2010), Huarng, Yu a Chen (2005).

Min, Lee a Han (2006) porovnávají predikativní výkon SVM (Support Vector Machines), neuronových sítí, rozhodovacích stromů a logistické regrese na případu predikce bankrotu. Dále navrhují metodu výběru vstupních charakteristik a optimalizaci parametrů SVM pomocí genetických algoritmů. Měření je prováděno na reálných datech 614 průmyslových korejských firem, z nichž 307 doznalo finančního bankrotu v letech 1999–2002. Bankrot je predikován na základě různých souborů dat proměnných s počtem 32, 30, 12 a 6. Nejvyšší klasifikační přesnosti dosahovali v případě modelu GA-SVM 80,3 % u modelu s 32 proměnnými a je nejvyšší hodnotou ve srovnání s ostatními modely, kdy logistická regrese dosahuje pouze 68 %, což je stejně jako je tomu u neuronových sítí.

Na základě dosavadních výzkumů ukázaly výsledky, že metody SVM a rozhodovací stromy jsou slibným přístupem pro vytvoření výstražných finančních modelů, srovnatelné s dalšími metodami umělé inteligence.

3.3.2 Empirické aplikace strukturálních modelů

Testování strukturálních modelů je obtížnější než v případě bankrotních modelů, kde jsou data ohraničená jasnými klasifikačními značkami: bankrot nebo přežití společnosti. Pro naše účely je užitečné zhodnotit, jaká je přesnost těchto modelů a zda existuje potenciál pro zlepšení klasifikace bankrotu nebo rizikovosti společností, ačkoliv v důsledku nedostupnosti některých tržních dat nejsme zpravidla schopni přesně replikovat kroky z níže uvedených studií. Pro naše účely ale mohou určité indukované proměnné posloužit jako vstupní proměnné do bankrotních modelů pro klasifikaci pomocí metody SVM.

Jednou z prvních prací s tímto zaměřením byl článek Jonese, Masona a Rosenfelda (1984), kteří testují Mertonův model na tržních datech různých typů dluhopisů a jejich spreadů u 15 společností z USA od roku 1977 do roku 1982. Z výsledků je patrné, že model ze třídy strukturálních modelů neposkytuje příliš kvalitní výsledky, resp. podhodnocuje rizika.

Sarig a Warga (1989), analyzovali kreditní rozpětí a časovou strukturu vybraných bezkupónových dluhopisů za období 1985 až 1987. Pro různé ratingové stupně se snažili zachytit, zda tvar výnosové křivky odpovídá empirickým údajům pro několik stovek údajů bezkupónových dluhopisů USA, ale i 42 amerických podniků a posoudit.

Mnoho autorů během testování základního Mertonova modelu dospělo k tomu, že výsledky výrazněji podhodnocují aktuální riziko, které je vyčíslené

v rámci tržních cen dluhopisů. To lze připočítat na vrub výraznějšího ovlivnění cen dluhopisů tržními, tzn. nekreditními vlivy.

Pro řešení problému likvidity a daní při modelování rozpětí různých dluhopisů se Leland (2004) zaměřil na vystihnutí pravděpodobností defaultu u společností s různým stupněm ratingu. Kalibroval modely s exogenní bariérou – Longstaffův a Schwartzův model a model s endogenní bariérou Lelanda a Tofta na datech úpadků amerických firem za roky 1970–2000. Pro srovnání doplnili výsledky získané modelem KMV. Hlavním záměrem bylo posoudit indukované defaultní pravděpodobnosti zejména z důvodu větší objektivity, než v případě hodnocení tržních cen kreditních spreadů. Z výsledku plyne, že modely podhodnocují počet defaultů pro krátké časové úseky, ale zároveň dokáží zachytit úroveň defaultů pro delší období. Do modelu bylo by vhodné zahrnout i skokovou složku, která by lépe zachytila vývoj hodnot aktiv.

Collin-Dufresne, Goldstein, a Martin (2001) používali regresní modely při zjišťování složení dluhopisových rozpětí při proměnných ze strukturálních modelů jako vysvětlujících proměnných. Tyto proměnné poskytovaly pouze 25% vysvětlení ve smyslu koeficientu determinace. Ani po doplnění dalších proměnných ze skupiny ekonomických nebo finančních se výsledky nezlepšily. Podle autorů existuje jen malá vysvětlující hodnota v samotných výstupech ze strukturálních nebo účetních modelů, ale existuje vysoká závislost na aktuální likviditě finančního trhu.

K podobným závěrům, tj. že volatilita akcií výrazně ovlivňuje rozpětí dluhopisů, dospěli i Campbell a Taksler (2003) také pro regresní modelování rozpětí dluhopisů.

Eom, Helwege a Huang (2004) testovali schopnost pěti strukturálních modelů k predikci rozpětí dluhopisů s jednoduchou kapitálovou strukturou. Konkrétně BSM, Geskeho, Lelanda a Tofta, Longstaffa a Schwartze, a finálně i Collin-Dufresne-Goldsteinův model. BSM model ovšem modifikují tak, že zahrnuje i kupónové platby a navíc v zobecněné podobě kvůli zachycení stochastické úrokové sazby. Práce vychází z tržních cen dluhopisů amerických nefinančních firem (finanční společnosti jsou dle autorů více zadlužené), které mají obchodovatelné akcie a jejichž kapitálová struktura je relativně jednoduchá. Sledovaným obdobím jsou roky 1986 až 1997. Autoři analyzují, do jaké míry se shoduje rozpětí, které generují zvolené modely oproti reálným hodnotám dluhopisových rozpětí. Z jejich výsledků plyne, že pro dluhopisy společností, které jsou málo rizikové, modely poskytují velice nízká rozpětí zvláště pro Mertonův a Geskeho model; avšak pro společnosti, které jsou vysoce rizikové (tzv. *junk bonds*) naopak rozpětí nadhodnocují. Tyto výsledky odlišné od ostatních studií, které většinou zmiňují podhodnocení rizika.

Obecným rysem výše uvedených studií je, že většinově vypovídají o nižších hodnotách pravděpodobnosti defaultu, než odpovídá historickým pro období do pěti let. Můžeme tedy očekávat, že tyto modely obecně nadhodnotí hodnoty dluhopisů i v případě, že se podaří korektně zachytit výši rizika. Proto je výhodnější využívat při analýze takové kontrakty, jejichž hodnota je více napojená na skutečné kreditní riziko. Popř. využívat přístupy, které přímo hodnotí pravděpodobnost rizika defaultu.

Leland (2004), Zhang, Zhou, a Zhu (2009), a McQuade (2013) zkoumali pravděpodobnosti defaultu odvozené strukturálními modely. Výhodou oproti kalibraci na CDS je zejména fakt, že pravděpodobnosti nejsou znehodnocené nelikviditou, recovery mírami a dalšími možnými faktory, existencí daní, skoky v hodnotě aktiv, které ovlivňují rozpětí dluhopisů.

Delianedis a Geske (1998) pomocí Mertonova a Geskeho modelu odhadují rizikově neutrální pravděpodobnosti defaultu, které dále používají k predikcím změn ratingů S&P, společností. Autoři provádějí analýzu za období let 1987 až 1996 na vzorku 600 až 1000 firem. Výsledky ukázaly, že oba dva modely jsou schopny predikovat změnu ratingu, popř. default, o několik měsíců dříve. Modely lze tudíž úspěšně používat k předpovídání pravděpodobností defaultu či k predikci změn ratingu. Tyto výsledky dokonce implikují skutečnost, že změny ratingu či defaultu jsou trhem již zaznamenány o několik měsíců dříve, než jsou skutečně realizovány a nejsou tudíž pro trh překvapením.

Komerční modifikace Mertonova modelu, která se využívá pro účely ratingu: KMV model společnosti Moody's a využívá tzv. vzdálenosti do defaultu (počet směrodatných odchylek do defaultu). Kealhofer a Kurbat (2002) došli k výsledkům, že model KMV zachycuje všechny informace, které jsou nutné pro změnu ratingu nebo poměrových ukazatelů, avšak výrazněji závisí na způsobu stanovení volatility aktiv. Bharath a Schumbway (2004) testovali přesnost KMV modelu proti jednodušším alternativám při využití vzdálenosti do defaultu jako proměnné v Coxově regresním modelu. Zjistili, že hodnoty CDS a dluhopisových rozpětí jsou jen málo korelované s pravděpodobnostmi, které generuje model KMV, tedy není vhodné využívat vzdálenost do defaultu jako primární prediktor. Avšak poskytovala určité vylepšení.

Podle Sobehart, Stein, Mikityanskaya, a Li (2000), kteří využívají data více než 1400 US nefinančních společností, které zdefaultovaly, k hodnocení KMV Merton modelu s dalšími proměnnými ke zhodnocení schopnosti Moodyho hybridního modelu. Přesněji využili kombinaci vzdálenosti do defaultu s proměnnými v podobě změn ratingu a účetními proměnnými. Podle autorů je výhodnější kombinovat tyto přístupy, výsledky jsou kvalitnější, než v případě, že pracujeme buď pouze s účetními nebo tržními ukazateli samostatně.

Proto v průběhu času převládají studie, které vycházejí z cen CDS kontraktů, u kterých se očekává nižší ovlivnění tzv. nedefaultovými faktory, než je tomu u dluhopisů. To znamená, že se lépe hodí k vysvětlování rizika defaultu. Toto zjištění odpovídá výsledkům, které přinesl Fisher (1959), že spready dluhopisů nezahrnují pouze kreditní, ale i tržní riziko.

Huang a Huang (2003) také ukazují, že faktory, které se nevážou ke kreditnímu riziku, jako je likvidita trhu, významně ovlivňují dluhopisové spready. Gemmill (2002) ukazuje, že Mertonův model funguje dobře v případě, že dluhopisy bez kupónu jsou využity jako jediný zdroj financování, v tom případě jsou spready generované modelem obdobné s těmi tržními.

Výstupy ze strukturálních modelů lze tedy chápat jako indikátory pro monitorovací účely, aby dali brzký signál blížícího se defaultu společnosti, ale nejedná se o vhodné ukazatele pro oceňování tržních kontraktů, které se pak následně obchodují na finančních trzích. Při aplikaci v bankrotních, resp. data miningových modelech se využívají proměnné, které jsou generované skrze modely strukturální.

4 Materiál a metody

4.1 Materiál

Data použitá k analýze pochází z Patria Online, Yahoo Finance (pro data akciových trhů) a databáze Amadeus. Volíme takové veřejně obchodovatelné společnosti z EU, které obsahují potřebné údaje pro analýzu, tedy pro výpočet pravděpodobností defaultu a bankrotu. Využíváme data společností středně velkých a velkých, které lze zařadit do skupiny výrobních nebo obchodních společností. Finanční společnosti do našich analýz nevstupují z důvodu vyššího zadlužení. I přes vysoké počty dostupných společností se ukázalo pouhých 90 společností jako adekvátních pro analýzu s kompletními údaji.

Datová analýza byla převážně provedena v programech R ve verzi 3.1.1 a Matlab 2014b². Využíváme i některých běžně známých metod, proto nepokládáme za nezbytné uvádět jejich detailnější matematický popis. Jedná se zejména o metodu shlukové analýzy pomocí Wardovy metody a metodu hlavních komponent (dále jen PCA od *Principal Component Analysis*). Bližší informace o těchto metodách lze získat např. z Holčík (2012).

4.2 Metodické kroky a použité kvantitativní techniky

Při práci využíváme několik ústředních kroků:

1. Výpočet pravděpodobností defaultu nebo bankrotu (Mertonův model, Mertonův D-Vine kopula model, Altmanův a Ohlsonův model), prostorové zachycení těchto atributů a srovnání mezi společnostmi.
2. Výběr různých skupin proměnných pro klasifikaci: tržní proměnné³ (pravděpodobnosti defaultu, volatilita akcií), finanční ukazatele.
3. Testování přesnosti při aktuální hodnotě proměnných i při zpoždění proměnných proti klasifikačním značkám (dynamický přístup). Tzn. ověření, zda lze predikovat budoucí stav krize, popř. s jakým předstihem je možné efektivně klasifikovat takové scénáře.

² Výpočty byly prováděny na osobním počítači s osmijádrovým procesorem FX 8350, 8GB RAM a grafickou kartou GTX 650 (technologie CUDA GPU pro paralelní výpočty nebyla využita), pod systémem Windows 7.

³ Do této skupiny řadíme výstupy, které mají vazbu na tržní proměnné, tedy volatilitu a poté pravděpodobnostní ukazatele. Na straně účetních proměnných stojí kromě poměrových ukazatelů i skóre získaná z Altmanova a Ohlsonova modelu.

4. Nastavení různých režimů pro klasifikaci: detekce rizikové situace v životě podniku (krize) v závislosti na zadluženosti, poklesu hodnoty rentability nebo poklesu aktiv; režim pro detekci bankrotu.
5. Hodnocení přesnosti klasifikace pomocí ROC a kontingenčních tabulek, pro dělení datového souboru na část tréninkovou, validační a testovací – pro různé poměry.

4.2.1 Finanční analýza

Pod pojmem finanční analýza se velmi často chápe technická analýza, jejímž základním nástrojem je výpočet a interpretace finančních ukazatelů. Z hlediska obtížnosti použitých matematických postupů existují dvě základní metody technické analýzy – elementární metody a pokročilé metody. Elementárností se v tomto případě má na mysli myšlenková jednoduchost při popisu složitých problémů. Finanční analýza poskytuje důležité a užitečné informace o tom, jaké je hospodaření podniku. Jako analytická metoda má však některá omezení, jež vyžadují větší pozornost a zdravý úsudek těch, kteří s výsledky finanční analýzy pracují. Pro analytika není vždy jednoduché posoudit, zda je dosažená hodnota určitého ukazatele uspokojivá, nebo příliš nízká, či naopak vysoká. V literatuře lze najít informace o výši doporučených hodnot k jednotlivým ukazatelům, ale zde je nutné varovat před využíváním těchto doporučených hodnot. Ty mohou sloužit pouze jako orientační vodítko. Každý podnik je velmi specifickým subjektem a vyžaduje individuální přístup k hodnocení finančního zdraví, to se týká i aplikací pro různá odvětví. V základu dělíme metody finanční analýzy na elementární a pokročilé – matematicko-statistické (Meritum, 2008):

1. Elementární (základní) metody:

- analýza stavových ukazatelů,
- analýza tokových a rozdílových ukazatelů,
- analýza poměrových ukazatelů,
- analýza soustav ukazatelů.

2. Pokročilé metody:

- **matematicko-statistické metody:** mezi tyto řadíme bodové odhady ukazatelů, intervalové odhady ukazatelů, regresní analýzu, korelační analýzu, autoregresní modelování, analýzu rozptylu, vícerozměrné analýzy, empirické distribuční funkce, statistické testy odlehlých dat, robustní matematicko-statistické postupy, apod.,

- **nestatistické metody:** mezi tyto řadíme neuronové sítě, expertní systémy, metody založené na teorii fuzzy množin, metody fraktální geometrie, metody formální matematické logiky, apod.

V práci se z pohledu finanční analýzy zaměřujeme na elementární přístupy – získáme proměnné v podobě poměrových ukazatelů, matematicko-statistické metody pro případ strukturálních modelů a nestatistické metody v podobě klasifikačních algoritmů.

4.2.2 Poměrové ukazatele v bankrotních modelech

Analýza pomocí poměrových ukazatelů bývá v praxi oblíbená, neboť umožňuje rychlou orientaci ve finanční situaci podniku díky účetním výkazům. Podstatou této metody je dávání do poměru různých položek rozvahy, výkazů zisků a ztrát, někdy i výkazů peněžních toků. Díky tomu můžeme nadefinovat velké množství ukazatelů, kterým lze i přiřadit ideální hodnoty. V praxi se však osvědčilo využívat jen určité skupiny ukazatelů, mezi něž patří:

- **Ukazatele zadluženosti** – podniky pro financování svých aktiv mohou využít buď vlastního kapitálu, nebo cizích zdrojů. Dnes je zejména u velkých podniků nemyslitelné využívat pouze jeden z těchto zdrojů, ale mít jejich určitou kombinaci (Knápková, 2010). Obecně platí, že cizí kapitál je levnější než vlastní. Není však možné financovat podniky pouze cizími zdroji už ze dvou důvodů – bylo by nesmírně obtížné získat takovýto úvěr a navíc česká legislativa požaduje určitou výši vlastního kapitálu. Jiným předpokladem o podnicích před bankrotem je, že jejich kapitálová struktura vykazuje větší podíl dluhu (viz Zavgren (1985)). Závažnost zadluženosti je nejčastěji posuzována relativně k hodnotě aktiv, neboli jako tzv. celková zadluženost. Celková zadluženost představuje poměr celkových závazků k celkovým aktivům. Takto definovaná zadluženost figuruje v řadě studií či modelů, viz Beaver (1966), Deakin (1972), Ohlson (1980) a Zavgren (1985).
- **Ukazatele rentability** – rentabilita indikuje schopnost podniku vytvářet nové zdroje. Firmám se doporučuje mít ukazatele rentability rostoucí v čase (Ručková, 2010). Nejčastěji užívaným měřítkem rentability je poměr zisku před zdaněním a nákladovými úroky a celkových aktiv, jedná se o nejsilnější prediktor většiny Altmanových modelů, viz Altman (1968), je také častou součástí dalších prací, viz například Li a Sun (2009) nebo Psillaki, Tsolas a Margaritis (2009). Rentabilita aktiv je často hodnocena i podle jiných úrovní generovaného zisku, zejména čistého zisku, mnoho modelů využívá těchto proměnných, viz Beaver (1966), Deakin (1972), Ohlson (1980) nebo Zmijewski

(1984). Kromě aktuální rentability aktiv se často využívá i tzv. kumulativní ziskovost, která je reprezentována poměrem nerozděleného zisku a celkových aktiv viz Altman (1968), resp. Ding, Song a Feng (2008).

- **Ukazatele likvidity** – aby byl podnik solventní, tak musí být likvidní. Jak uvádí Kislingerová (2010), likvidita je vyjádřením schopnosti podniku přeměnit svá aktiva na peněžní prostředky a těmi krýt včas, v požadované době a na požadovaném místě všechny splatné závazky. Bohužel velká míra likvidity se projevuje na úkor rentability. Je tedy zřejmé, že akcionáři nebudou stát o příliš vysokou likviditu, naopak věřitelé ano, viz Ručková (2010). Jedním ze znaků finančních obtíží podniku nebo bankrotu podniku je jeho neschopnost dostat svým splatným závazkům v krátkém období, proto jsou faktory likvidity často součástí bankrotních modelů. Nejčastějším měřítkem likvidity v bankrotních modelech je relativní velikost čistého pracovního kapitálu. Alternativním měřítko likvidity, na bázi čistého pracovního kapitálu, představuje poměr čistého pracovního kapitálu a tržeb, který byl analyzován v řadě studií, viz Beaver (1966), Deakin (1972) nebo Ohlson (1980).
- **Ukazatele aktivity** – jak uvádí Ručková (2010) ukazatele aktivity měří schopnost společnosti využívat investované finanční prostředky a vázanost jednotlivých složek kapitálu v jednotlivých druzích aktiv. Jedná se tedy především o počet obrátek nebo o dobu obratu. Jinou často zmiňovanou příčinou bankrotu je nedostatek kapitálu pro obchodní řízení firmy, viz Deakin (1972). Nedostatek provozního kapitálu je patrný zejména z hodnot obratu aktiv, tj. poměru tržeb a celkových aktiv, viz studie Altman (1968, 1977) nebo Ding a kol. (2008), či ve složení aktiv jako u Psillaki, Tsolas a Margaritis (2009). Podle obratu aktiv lze hodnotit schopnost managementu obstát v konkurenci.
- **Ukazatele kapitálového trhu neboli tržní proměnné** (Knápková, 2010) – tyto ukazatelé se od ostatních liší tím, že se při jejich výpočtu pracuje s tržní hodnotou, proto bývají někdy nazývány „ukazatelé tržní hodnoty“. Jelikož vyjadřují hodnocení firmy pomocí burzovních ukazatelů, tak jsou důležité zejména pro možné investory (Ručková, 2010). Campbell, Hilscher, a Szilagyi (2008) využívali jako proměnné pro predikce defaultu tržní hodnoty aktiv místo hodnoty účetní. Argumentují tím, že takto stanovená hodnota lépe reflektuje budoucí perspektivu firmy. Campbell, Hilscher a Szilagyi (2008) doporučují jako ukazatel velikosti společnosti využít zlogaritmovanou tržní kapitalizaci místo zlogaritmovaných celkových aktiv. Další proměnnou je u těchto autorů výnos nad úrovní indexu S&P 500. Další využívanou proměnnou je hodnota volatility výnosů, která indikuje hodnotu rizika, které společnosti čelí.

- **Ukazatele velikosti společnosti** – bylo prokázáno, že samotná velikost podniků může z hlediska bankrotu představovat významný rizikový faktor a zároveň je větší společnost stabilnějším partnerem. Z informačního hlediska vnáší do modelů aspekt tržní pozice, např. Altman (1977), Ding a kol. (2008), Psillaki, Tsolas a Margaritis (2009). Shumway (2001) zmiňuje faktory velikosti podniku odvozené z tržních dat jako velmi významné prediktory bankrotu.

Je jasné, že existuje velké množství možných ukazatelů, proto se dostupné studie snažily ozřejmit, které proměnné jsou vhodné pro klasifikaci bankrotujících společností, resp. jakým způsobem redukovat velké číslo proměnných na nižší. Ve své podstatě existují dva způsoby, jak redukovat množství proměnných, které finálně vstupují do modelování. Jeden vyplývá z výběru proměnných, které byly dříve využité v literatuře, a druhý spočívá v hodnocení statistické nebo informační významnosti proměnných. Tabulka 2 informuje o výběru proměnných, které byly dříve použité ve vybraných studiích.

Tab. 2 Vybrané proměnné využívané ke klasifikaci uváděné v literatuře

Ukazatel	Autor
ČPK/CA	Altman (1968)
EBIT/CA	Altman (1968)
Tržby/CA	Altman (1968)
VK/CD	Altman (1968)
Zadržené zisky/CA	Altman (1968)
VK/CD	Altman (1968)
Log(kapitalizace)	Campbell (2008)
Log(Cena za akcii)	Campbell (2008)
CA/CD	Deakin (1972)
CA/Tržby	Deakin (1972)
CD/ CA	Deakin (1972)
CF/S	Deakin (1972)
CF/CA	Deakin (1972)
CF/TL	Deakin (1972)
ČPK/Tržby	Deakin (1972)
OA/CA	Deakin (1972)
EAT	Ohlson (1980)
KD/OA	Ohlson (1980)
VK	Ohlson (1980)
Roční volatilita akcií	Shumway (2001)

Průměrné zásoby/Tržby	Zavgren (1985)
Pohledávky/Zásoby	Zavgren (1985)
Čisté tržby/(FA+ ČPK)	Zavgren (1985)
DD/(CA – KD)	Zavgren (1985)
Oběžná aktiva/CA	Zavgren (1985)
Oběžná aktiva/KD	Zavgren (1985)
Příjmy z provozní činnosti/CA - KZ	Zavgren (1985)
EAT/OA	Zmijewsky (1984)

Pozn. *CF* (cash flow), *DD* (dlouhodobý dluh), *EAT* (čistý zisk), *CD* (celkový dluh), *ČPK* (čistý pracovní kapitál), *CA* (celková aktiva), *VK* (vlastní kapitál), *KD* (krátkodobý dluh)

Výběr proměnných je v data miningu velice důležitý, protože umožňuje poznat, které proměnné nejvíce ovlivňují výstupní proměnnou. Při výběru proměnných si klademe za cíl identifikovat a odebrat co nejvíce irelevantních nebo duplicitních informací. V rámci práce jsme se rozhodli spoléhat na volbu ze strany klasifikačních algoritmů (u metody podpůrných vektorů a rozhodovacích stromů), které sami přiřazují váhu atributům. Jednáme tak zejména kvůli předchozím výsledkům v pracích Klepáč a Hampel (2016a, 2016b, 2016c), ze kterých se jeví volba proměnných pomocí expertních filtračních metod (nad rámec hodnocení multikolinearity dat) jako neprůkazná nebo obtížně zobecnitelná pro zkvalitnění odhadu rizika – výrazný vliv zde hraje použitý datový soubor i rozdělení setu na tréninkovou, validační a testovací část.

4.2.3 Odhad pravděpodobnosti defaultu společností

Při odhadu pravděpodobnosti defaultu pomocí Mertonova a Blackova-Coxova modelu využíváme proměnné, které nám dále poslouží ke klasifikaci v bankrotních modelech:

- Anualizovaná volatilita vlastního kapitálu – historická hodnota volatility pro vývoj akciového trhu, odhadnutá modelem pomocí procesu na základě GARCH. Hodnotu průměrné denní volatility převedeme do ročního vyjádření (anualizace). Míšek (2006) ve svojí práci využívá jednoduchého modelu GARCH bez podmíněného procesu střední hodnoty, z našich zkušeností a testování mnoha modelů je výhodnější využívat modely kombinované. Proces na bázi GARCH (1, 1) pro odhad volatility akcií ve své studii využívají i Eom, Helwege a Huang (2004).

- Tržní kapitalizace společnosti jako násobek počtu akcií a jejich tržní hodnoty, pro určený časový okamžik.
- Bezriziková úroková sazba zemí EU.
- Délka splatnosti dluhopisu – jelikož nás zajímá odhad pravděpodobnosti defaultu ve střednědobém horizontu, volíme v tomto případě pětiletý horizont.
- Výše defaultní bariéry – v tomto kroku využíváme metodiky KMV (Crosbie and Bohn, 2003). Výše se rovná krátkodobým závazkům a jedné polovině dlouhodobých závazků.
- Hodnota volatility aktiv společnosti – proměnná získaná pomocí systému rovnic.
- Tržní hodnota aktiv – proměnná ze systému rovnic.

Problematické je zde zejména stanovení tržní hodnoty aktiv a jejich volatility, protože se jedná o nepozorovatelné ukazatele. Pro tento účel byly testovány různé procedury, viz Bharath a Shumway (2008), Vassalou a Xing (2004) nebo Duffie, Saita, a Wang (2007). My využíváme jednu z méně komplikovaných možností odhadu, kdy řešíme systém nelineárních rovnic pomocí Raphsonovy-Newtonovy metody. Ze soustavy dvou rovnic o dvou neznámých získáváme volatilitu aktiv S_t i jejich tržní hodnotu

$$S_t = A_t N(d_1) - e^{-r(T-t)} KN(d_2), \quad (24)$$

$$\sigma_t = N(d_1) \frac{A_t}{S_t} \sigma. \quad (25)$$

Výsledek je platný v krátkém časovém okamžiku a hodnota volatility aktiv může být ovlivněna poklesem finanční páky podniku, což nadhodnotí pravděpodobnost defaultu a naopak. Pravděpodobnost defaultu je v Mertonově modelu

$$PD_{Mertonův\ model} = 1 - N(d_2), \quad (26)$$

kde $N(d_x)$ je výstupem normální kumulované distribuční funkce a d_2 je

$$d_2 = d_1 - \sigma_A \sqrt{T - t} \quad (27)$$

a

$$d_1 = \frac{\ln \frac{A_t}{L} + (r + \frac{\sigma^2}{2})(T-t)}{\sigma \sqrt{T-t}}. \quad (28)$$

V případě Blackova-Coxova modelu můžeme podle Schoutense a Cariboniové (2009) psát rizikově-neutrální pravděpodobnost přežití společnosti do času t následovně:

$$PD_{Blackův-Coxův\ model} = 1 - (N(d_3) - \frac{K(\frac{2r}{\sigma^2})^{-1}}{A_t} N(d_4)), \quad (29)$$

kde

$$d_3 = \frac{\ln \frac{A_t}{L} + (r - \frac{\sigma^2}{2})(T-t)}{\sigma \sqrt{T-t}} \quad (30)$$

a

$$d_4 = d_3 - \sigma_A \sqrt{T-t}. \quad (31)$$

Výpočet pravděpodobnosti defaultu u našeho odvozeného modelu Merton-D-Vine Copula, který vychází z simulace MC trajektorií vývoje aktiv je blíže popsán v následující podkapitole.

Výpočet rizika pomocí Altmanova a Ohlsonova modelu provádíme pomocí logistické transformace Z-skóre a O-skóre stejně jako Peška (2005), čímž dostaneme hodnotu z intervalu 0 až 1. Pro Altmanův model platí, že čím vyšší hodnota skóre, tím nižší pravděpodobnost defaultu

$$PD_{Z-skóre} = \frac{1}{1 + e^{Z-skóre}}. \quad (32)$$

Ohlsonův model a skóre z něj získané také transformujeme na pravděpodobnosti. Platí, že čím vyšší hodnota O-skóre, tím vyšší pravděpodobnost defaultu/bankrotu

$$PD_{O-skóre} = \frac{e^{O-skóre}}{1 + e^{O-skóre}}. \quad (33)$$

Prosté hodnocení pravděpodobnosti defaultu dává rychlý ukazatel pro praktické vzájemné hodnocení rizika a hrubou klasifikaci společností, ačkoliv při praktické klasifikaci může dojít i k dalším scénářům neboli chybám 1. a 2. stupně, jejichž hodnocení je také důležité.

4.2.3.1 Odhady modelů volatility pro účely strukturálních modelů rizika

Vhodný model volatility vybíráme ze standardních modelů GARCH, GJR, EGARCH, APARCH, iGARCH, které jsou nejdříve testované tzv. ve výběru⁴ podle vyhledání minimální hodnoty Akaikeho nebo Bayesovského kritéria, které v sobě zahrnuje i posouzení t-statistiky pro různé kombinace zpoždění (až do 5. řádu) pro všechny části procesu ARMA. Testujeme zároveň i různá rozdělení distribuce inovace: General error distribution (ged), Student-t, Hansen Skewed-t, Gaussian, Normal Inverse Gaussian (NIG). Blíže je postup popsán v Klepáč a Hampel (2015), kde

$$X_{i,t} = \mu_{i,t} + \sqrt{h_{i,t}}z_{i,t}, \quad (34)$$

kde $z_{i,t}$ je výběrem z inverzní kumulativní distribuce, $h_{i,t}$ je podmíněný rozptyl, $\mu_{i,t}$ je podmíněný proces střední hodnoty, $X_{i,t}$ značí i -rozměrný vektor výnosů. Jednoduchý GARCH (1,1) proces je zde značen jako

$$h_{i,t} = \omega_i + \alpha_i e_{i,t-1}^2 + \beta_i h_{i,t-1}, X_{i,0} = 0, h_{i,0} = 0, \quad (35)$$

kde $\omega_i > 0$, $\alpha_i \geq 0$, $\beta_i \geq 0$, $e_{i,t}$ je reziduální část, $h_{i,t}$ značí varianci. V případě D-Vine kopule zde $h_{i,t}$ slouží jako závislostní struktura mezi reziduálními komponentami $e = (e_{1,t}, \dots, e_{n,t})'$ kde pro fixní t je definována n -rozměrná D-Vine hustota podle rovnice (11) v článku Czado (2010). Rovnice je abstraktním způsobem, jak označit více-rozměrné i jednorozměrné modely GARCH; pro $i = 1$ hovoříme o jednorozměrných modelech jako je například ARMA-GARCH.

4.2.3.2 Aplikace Vine kopula funkce na datech finančního trhu

V případě D-Vine kopulí modelujeme závislost mezi prvky, které jsou na stejné úrovni závislosti. Využití těchto modelů je doposud četné zejména při modelování výnosů nebo odhadu rizikových metrik VaR nebo cVaR, blíže viz Klepáč a Hampel (2015). Dále dělíme rezidua odhadnutou volatilitou, čímž je tzv. standardizujeme. Následně transformujeme data reziduí na rovnoměrně rozdělená data na intervalu $[0,1]$, pomocí algoritmu *tcdf* v programu Matlab. S takto upravenými daty provádíme kroky, které uvádí ve článku Aas a kol. (2010):

- Výběr struktury závislosti.
- Provedení Vuongova-Clarkova testu pro odhad kopula funkce.
- Odhad kopula parametrů pomocí metody maximální věrohodnosti (MLE), kdy využíváme kopule s jedním nebo dvěma parametry.

⁴ Také se využívá výrazu *in sample*.

- Zhodnocení pomocí Vuongova testu a podle informačních kritérií.
- Simulace z D-Vine kopula rozdělení, v našem případě generujeme 10000 identicky rozdělených hodnot.

Pro odhad vhodné kopula funkce využíváme kroky popsané v Aas kol. (2009). V první fázi filtrujeme data pomocí procesu ARMA, tak aby rezidua byla zbavena autokorelační struktury. Popis modelu ohledně vytvoření D-Vine kopula ARMA-GARCH je uveden v Hofman a Czado (2010) a v článku Krauseho (2003).

V práci při odhadu na datech využíváme dílčí dvourozměrné kopule, které jsou blíže popsány v Tabulkách 3 a 4 s tím, že algoritmus pro odhad Vine kopulí v programu R dokáže běžně hodnotit i kopule různým způsobem rotované ke každé ze zde uvedených (avšak my předpokládáme nerotovanou podobu, která se ukázala z dřívějších prací jako běžnější). Využíváme dvě třídy kopulí: eliptické a Archimédovy. Přičemž Archimédovy definujeme vztahem

$$C(u, v) = \varphi^{-1}(\varphi(u) + \varphi(v)), \quad (36)$$

kde φ značí generátor funkce. Vztah mezi generátorem a Kendallovým tau je zde

$$\tau = 1 + 4 \int_0^1 \frac{\varphi(t)}{\varphi'(t)} dt. \quad (37)$$

Tab. 3 Dostupné Archimédovy kopule

Archimédovy kopule	Rozpětí parametrů	Ocasová závislost	Generátor	Kendalovo tau
Claytonova	$\theta > 0$	$(2^{-\frac{1}{\theta}}, 0)$	$\frac{1}{\theta}(t^{-\theta} - 1)$	$\frac{\theta}{\theta + 2}$
Gumbelova	$\theta \geq 0$	$(0, 2 - 2^{-\frac{1}{\theta}})$	$(-\log t)^\theta$	$1 - \frac{1}{\theta}$
Frankova	$\theta \in \mathbb{R} \setminus \{0\}$	$(0, 0)$	$-\log\left(\frac{e^{-\theta t} - 1}{e^{-\theta} - 1}\right)$	$1 - \frac{4D(\theta)}{\theta}$
Joeova	$\theta > 1$	$(0, 2 - 2^{-\frac{1}{\theta}})$	$-\log(1 - (1-t)^\theta)$	$1 + \frac{4}{\delta\theta} \int_0^1 t \log(t)(1-t)^{2(1-\theta)/\theta} dt$
Claytonova-Gumbelova	$\theta > 0, \delta \geq 1$	$(2^{-\frac{1}{\delta\theta}}, 2 - 2^{-\frac{1}{\delta}})$	$(t^{-\theta} - 1)^\delta$	$1 - \frac{2}{\delta(\theta + 2)}$
Joeova-Gumbelova	$\theta \geq 1, \delta \geq 1$	$(0, 2 - 2^{-\frac{1}{\delta\theta}})$	$(-\log(1 - (1-t)^\theta))^\delta$	$1 + \frac{4}{\delta\theta} \int_0^1 -\log(1 - (1-t)^\theta)(1-t)((1 - (1-t)^\theta)^\delta) dt$
Joeova-Claytonova	$\theta \geq 1, \delta \geq 0$	$(2^{-\frac{1}{\delta}}, 2 - 2^{-\frac{1}{\theta}})$	$-\log\left(\frac{1 - (1-\delta t)^\theta}{1 - (1-\delta)^\theta}\right)$	$1 + \frac{4}{\delta\theta} \int_0^1 (-(1 - (1-t)^\theta)^{\delta+1} \frac{(1 - (1-t)^\theta)^\delta - 1}{(1-t)^{\theta-1}}) dt$

Eliptické kopule (nejznámější jsou Studentovy a Gaussovy, viz Tab. 4) jsou odlišné od Archimédových – jsou radiálně symetrické a nemají analytické vyjádření. Vztah mezi lineárním korelačním koeficientem a Kendallovým tau je

$$\rho(X, Y) = \sin\left(\frac{\pi}{2} \tau\right). \quad (38)$$

Vztah pro Gaussovu dvourozměrnou kopuli je

$$C(u, v) = \int_{-\infty}^{\Phi^{-1}(u)} \int_{-\infty}^{\Phi^{-1}(v)} \frac{1}{2\pi(1-\rho^2)^{1/2}} \exp\left(-\frac{x^2-2\rho xy+y^2}{2(1-\rho)^2}\right) dx dy, \quad (39)$$

kde Φ^{-1} je inverzní hodnota standardizované normální distribuční funkce a ρ je lineární korelační koeficient. Vztah pro Studentovu eliptickou dvourozměrnou kopuli je

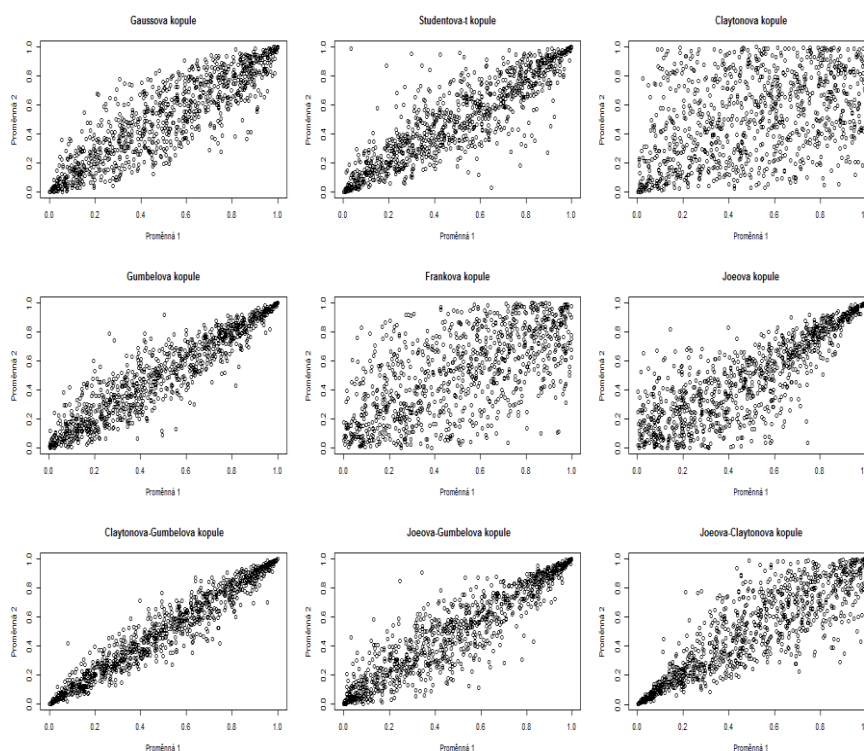
$$C(u, v) = \int_{-\infty}^{t_v^{-1}(u)} \int_{-\infty}^{t_v^{-1}(v)} \frac{1}{2\pi(1-\rho^2)^{1/2}} \left(1 + \frac{x^2-2\rho xy+y^2}{v(1-\rho)^2}\right) dx dy, \quad (40)$$

kde v je počet stupňů volnosti (při vysokých hodnotách, kdy $v > 30$ konverguje k normální kopuli, při nižší hodnotě počtu v má více realizací v oblasti chvostů rozdělení než normální) a ρ je lineární korelační koeficient. Bližší informace o matematických vztazích uvedených v Tabulkách 3 a 4 lze nalézt například v Joe (1996) a Nelsen (2006) nebo teoretické části dizertační práce.

Tab. 4 Dostupné eliptické kopule

Eliptické kopule	Rozpětí parametrů	Závislost chvostu	Kendallovo tau
Gaussova	$\rho \in (-1, 1)$	0	$\frac{2}{\pi} \arcsin(\rho)$
Studentova-t	$\rho \in (-1, 1), v > 2$	$2t_{v+1} \left(-\sqrt{v+1} \sqrt{\frac{1-\rho}{1+\rho}} \right)$	$\frac{2}{\pi} \arcsin(\rho)$

Cílem Obr. 2 je ukázat, jaká je závislost v rámci simulovaných dat mezi proměnnými. U jednoparametrických kopulí ve výběru (Gaussova, Claytonova, Gumbelova, Frankova, Joeova kopule) se projevuje změna parametru pro korelaci proměnných výrazně. Na Obr. 2 znázorněný případ, kdy je tau = 0,9, značí silnou pozitivní závislost. U kopulí se dvěma parametry záleží výrazněji na druhém parametru chvostové závislosti, který určuje, jaké bude rozložení dat v oblasti okrajových hodnot. Tučně vyznačené body indikují vyšší koncentraci dat na těchto místech, což je pro případ finančních časových řad zřetelné zejména u chvostů distribučních funkcí.



Obr. 2 Simulace 1000 vzorků ze dvourozměrných kopula funkcí (Kendalovo tau = 0,9), těžké konce indikují vysokou horní nebo dolní závislost v této oblasti

4.2.4 Sestavení algoritmu Merton-D-Vine kopula

Vycházíme z teoretického předpokladu, že se kreditní kvalita společností – vyjádřená vývojem aktiv společnosti jako znázornění budoucí perspektivy společností, vyvíjí určitým způsobem spolu s vývojem jejich akcií. Dalším předpokladem je možnost, že se vývoj akcií společností vyvíjí v rámci konkrétního systému, kde lze měřit závislost mezi vývojem výnosů v rámci definovaných skupin.

Na tomto základě lze definovat prognostický model, který promítne závislosti mezi vývojem firem na finančním trhu do vývoje jejich aktiv. Požadavkem na zde navržený model je zachytit pravděpodobnost rizika defaultu, kterou můžeme dále využít jako proměnnou do predikčních modelů, díky zachycení vztahu v rámci finančních dat.

Konkrétně simulujeme chování základního Mertonova modelu, na základě numerického řešení modelu evropské kupní opce s parametry, které se zde běžně využívají při odhadu defaultu s tím rozdílem, že hodnota aktiv je řízena Brownovým pohybem. Jeho složka, která odpovídá Wienerovu procesu s normálním

rozdělením, je nahrazena D-Vine kopula složkou se Studentovým-t rozdělením. Tedy základní vztah

$$dV_t = \mu V_t dt + \sigma V_t dW_t \quad (41)$$

je upraven do podoby vývoje tržní hodnoty aktiva jedné společnosti s Vine kopulí

$$dV_t = \mu V_t dt + \sigma V_t dt(D - Vine\ kopula_t), \quad (42)$$

vyjádření pro i společností

$$dV_t^i = \mu^i V_t^i dt + \sigma_i V_t^i dt(D - Vine\ kopula_t^i), \quad (43)$$

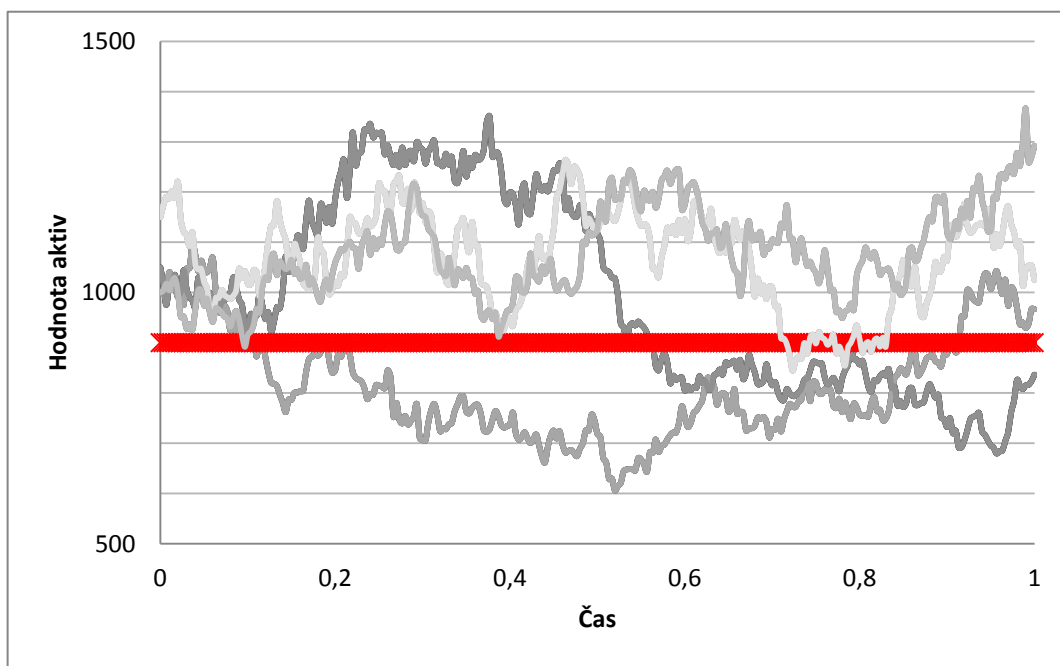
kde hodnota σ značí analýzovanou hodnotu volatility aktiva, která je konstantní po celou dobu do splatnosti dluhopisu. $D - Vine\ kopula_t$ je výběrem z normovaného D-Vine kopula rozdělení, které získáme na základě provedených simulací, tak aby zachycovalo strukturu závislosti mezi výnosy akcií společností. Pro odhad střední hodnoty procesu μ volíme způsob uvedený Campbellem, Hilscherem a Szilagym (2008), kdy $\mu = r + 0,06$, kde r je bezriziková sazba.

Změna oproti standardnímu Mertonovu procesu spočívá ve skutečnosti, že inovace procesu obsahují vnitřní korelační strukturu a budou generované ne-normálním rozdělením. Technicky se jedná o inverzní transformaci provedenou algoritmem *tcdf* v programu Matlab, kde jsou vstupem data ze simulace D-Vine kopule, které mají uniformní rozdělení na intervalu [0–1]. Určitým nedostatkem je zde skutečnost, že odvození hodnoty aktiva a volatility předpokládá jejich log-normální, resp. normální rozdělení. Proto doplníme odvození pravděpodobnosti defaultu i o odhad rizika na základě vícerozměrné D-Vine Gaussovy kopule, tak aby odpovídalo teoretickým předpokladům, i přesto, že pro finanční data je výhodnější využívat nastavení na non normální výnosy, jak plyne z analýzy v práci Klepáč a Hampel (2015) pro data českého finančního trhu. Při simulaci vycházíme z postupu, který pro účely numerického oceňování opcí uvádí web společnosti Goddard Consulting (2011):

1. Kalkulace budoucího vývoje hodnoty podkladového aktiva – výstupem je několik tisíc trajektorií vývoje, na základě stanovené funkce vývoje aktiva, kdy vývoj rozdělíme do malých diskrétních úseků.
2. Výpočet terminálních hodnot opcí pro každou z potenciálních trajektorií.
3. Výpočet průměru ze všech terminálních opčních hodnot a jejich diskontování pro získání současné hodnoty.

Cílem je určit četnost průniků defaultní bariéry v čase splatnosti dluhopisu, kterou lze chápat podle opční teorie jako pravděpodobnost, že společnost zdefaultuje

v konkrétním časovém okamžiku. Proto využíváme pouze první z výše uvedených kroků. Pro lepší dokreslení modelování znázorníme vývoj hodnoty aktiva v rámci Mertonova modelu spolu s konstantní bariérou na Obr. 3.



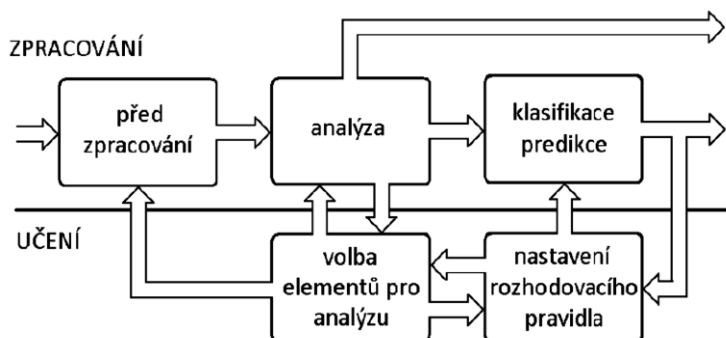
Obr. 3 Výběr ze simulace trajektorií vývoje hodnoty aktiva pro 1 společnost (trajektorie pod červenou hranicí (v čase 1) značí default)

4.3 Data miningová analýza a klasifikace

Práce je do značné míry založená na hromadném zpracování dat, na základě ekonometrických a data miningových metod. Při klasifikaci se řídíme procesem popsaným na Obr. 4.

V práci je pro nás kromě samotné analýzy důležitá i část předzpracování, ve které využíváme metodu hlavních komponent, normalizaci a centrování. Podle Holčíka (2012) a jeho nasměrování na data mining, resp. strojové učení, lze tvrdit, že "Kvůli možnosti srovnání hodnot různých veličin se často hodnoty veličin upravují např. centrováním (odečtení střední hodnoty), normalizací (vztažení hodnoty proměnné k nějak definované normě), resp. standardizací (centrovaná hodnota je vztažena k určité specifické hodnotě, často např. k směrodatné odchylce). Návrh parametrů rozhodovacího pravidla pak standardně vede na použití nějaké optimalizační úlohy. Děje se to na základě tzv. učební nebo tréninková množiny, která obsahuje vstupní obrazy spojené s informací o předpokládané správné klasifikaci

(uspořádané dvojice datového popisu a identifikátoru klasifikační třídy). V tom případě hovoříme o učení s učitelem, a podle míry spolehlivosti údaje o předpokládané klasifikaci rozlišujeme algoritmy učení s dokonalým či nedokonalým učitelem.



Obr. 4 Blokové schéma zpracování dat (převzato z Holčík (2012))

V případě, že tréninková množina není k dispozici, pak blok nastavení rozhodovacího pravidla obsahuje pouze návrh jeho obecného tvaru a případné nastavování parametrů rozhodovacího pravidla probíhá současně s klasifikací. Tento postup označujeme jako učení bez učitele. Typickým příkladem je i shlukování." Při učení bez učitele tedy algoritmus nezná přesné označení skupin, ale pouze se snaží o přiblížení podobných objektů podle hodnot jejich vstupních proměnných. Klasifikací rozumíme rozdělení dané (konkrétní či teoretické) skupiny (množiny) objektů, jevů či procesů na konečný počet dílčích skupin (podmnožin), v nichž všechny objekty, jevy či procesy mají dostatečně podobné společné vlastnosti. Při modelování postupujeme v těchto krocích:

- Volba proměnných – plynoucí z literatury, dřívějšího výzkumu (viz Klepáč a Hampel (2016b)) a ukazatelů finanční analýzy. Pro klasifikaci skrze shlukovou analýzu volíme 4 klíčové proměnné, které slouží jako hranice pro umělé stanovení, zda je společnost riziková nebo neriziková. Jedná se o ukazatel běžné likvidity (rizikové společnosti pod hodnotou 1), pozitivní nebo zápornou hodnotu EBIT v předchozím období, ukazatel Solvency ratio (rizikové společnosti pod 50%) a ukazatel zadluženosti (rizikové společnosti nad 50%). V případě rozhodovacích stromů a metody SVM pracujeme se značkami určenými pouze z běžné likvidity a ukazatele míry zadluženosti – na stejné číselné úrovni. Solvency ratio prezentuje podíl vlastního kapitálu na celkovém, míra zadluženosti ukazuje poměr cizího kapitálu s celkovým, viz Tabulka 5 pro bližší přehled o proměnných.

Tab. 5 Použité proměnné


Ukazatel	
Solvency ratio (z aktiv v %), ukazatel samofinancování	Vlastní kapitál/Celková aktiva
Míra zadluženosti – Gearing (%)	Dlouhodobé závazky a úvěry/Vlastní kapitál
Obrat (tis. EUR)	
EBIT (tis. EUR)	
Fixní aktiva/Celková aktiva	
Čistý pracovní kapitál (tis. EUR)	
Celková aktiva (EUR)	
Čistý pracovní kapitál/Celková aktiva	
Cash flow/Celková aktiva	
EBIT/Celková aktiva	
Obrat aktiv	Obrat/Celková aktiva
Doba obratu pohledávek (dny)	Součet pohledávek/Tržby * počet dní v roce
Doba obratu dluhů (dny)	Závazky/Tržby * počet dní v roce
Běžná likvidita	Oběžná aktiva upravená/Krátkodobý cizí kapitál
Obrat čistých aktiv	Tržby/Celková aktiva-Celkové závazky
Úrokové krytí	Úroky/EBIT
Cash flow (tis. EUR)	
Pohotová likvidita	(Oběžná aktiva upravená – Zásoby)/Krátkodobý cizí kapitál
EBIT marže (%)	(EBIT / Provozní výnosy)
ROE (%) po zdanění	Čistý zisk/Vlastní kapitál
ROA (%) po zdanění	Čistý zisk/Celková aktiva

- Rozdělení dat na tréninkovou skupinu dat a testovací (30%/30%/40%).
- Statistické transformování nebo redukce dimenze dat.
- Trénink na datech.
- Diagnostika přesnosti klasifikátoru na testovacím souboru dat pomocí kontingenční tabulky.

4.3.1 Klasifikace pomocí shlukové analýzy

V základu nemá shluková analýza přiřazené značky, ale my je v našem případě manuálně doplníme, abychom zjistili, zda mají tyto metody přínos ve smyslu klasifikace. Zjistíme, zda se podařilo shlukovou analýzou separovat nebo alespoň přiblížit soubory finančních ukazatelů společností, které mají obdobný rizikový

profil dle zadluženosti, likvidity nebo výše kreditního skóre. Tento přístup explorační datové analýzy byl využit v článku Piterkové a kol. (2013) při analýze rizikovitosti pomocí základních finančních ukazatelů zemědělských podniků nebo v práci Klepáč a Kamarýtová (2015) na datovém vzorku maloobchodních společností. Výstup tvoří dendrogram jako např. na Obr. 5, který slouží zejména pro lepší pochopení dat a polohy jednotlivých společností v rámci datového souboru. Stejně jako Piterková, Bieliková a Bányiová (2013) využíváme k provádění shlukové analýzy pouze významné komponenty, které získáme pomocí metody hlavních komponent.




Obr. 5 Dendrogram společností (R- rizikové a N-nerizikové) přes Wardovu metodu (převzato z Klepáč a Kamarýtová (2015))

4.3.2 Klasifikace pomocí metody podpůrných vektorů

V dalších krocích práce využíváme binární klasifikační metodu Support vector machines (dále jen SVM) neboli algoritmus podpůrných vektorů. Tento neparametrický algoritmus, který vyplývá ze statistické teorie učení, poprvé uvedený Vapnikem (1995) je vytvořen ke klasifikaci, ale také k regresi. Jeho výhoda spočívá v jeho podstatě – snaží se nabídnout efektivní algoritmy pro nalezení hranice mezi objekty, které dokáží zachytit i složité nelineární funkce.

Problémy, které řešíme při měření rizik jsou často vícerozměrné, modely by měly pracovat s non-normálními distribucemi, standardní metody jako je metoda maximální věrohodnosti je nahrazena jiným způsobem – strukturální minimalizací rizika (SRM). Metody SVM se osvědčily zejména při modelování dat, kde není k

dispozici velká tréninková množina. Výhodou SVM je jistě fakt, že nabízí při učení jen jedno optimální řešení – jedná se o řešení úlohy kvadratického programování. SVM vytváří binární klasifikátor, optimální separabilní nadrovinu, skrze převod lineárních vektorů dat do vícerozměrného prostoru. SVM vytváří lineární model k odhadu rozhodovací funkce při užití nelineární třídy založené na podpůrných vektorech. Pokud jsou data lineárně separovatelná, využíváme lineární SVM algoritmy, které rozdělí data bez chyb na třídy, jejichž hranice nadrovin mají co největší možnou vzájemnou vzdálenost. Ostatní body kromě podpůrných bodů nejsou zapotřebí. Obr. 6 zobrazuje dvě třídy dat (modré a růžové body) a podpůrné vektory, které jsou na okrajích dělicího prostoru.



Obr. 6 Vizualizace podpůrných vektorů (body na hranicích jsou podpůrné vektory, vzdálenost od hranice znázorňují šipky) v tomto případě pomocí lineárního jádra (převzato z James (2013))

V případě metody SVM pro případ lineárně separovatelných dat můžeme definovat úlohu podle vztahu

$$Y = \text{sign}(\sum_{i=1}^N y_i \alpha_i (x \cdot x_i) + b), \quad (44)$$

kde je Y je výstup, Y_i je hodnota třídy tréninkového příkladů x_i , \cdot je značkou pro vnitřní produkt. Vektor $x = (x_1, x_2, \dots, x_n)$ odpovídá vstupním datům a vektor x_i značí podpůrné vektory, parametry α a b určují nadrovinu. Pro případ nelineárně separovatelných tříd, kdy využíváme vícerozměrnou verzi vztahu, princip učení spočívá v minimalizaci chyb při tréninku. Matematicky se jedná o vztah hledání Lagrangianu α_i skrze hledání řešení pro optimalizační problém maximalizace

$$\theta(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (45)$$

s podmínkami

$$\sum_{i=1}^n \alpha_i y_i = 0, \quad (46)$$

kde $0 \leq \alpha_i \leq C$, $i = 1, 2, \dots, n$. Přičemž C je parametr pro nastavení tréninkové chyby. Parametr α_i je určen uživatelem. Pro řešení těchto problémů s nelineární separovatelností


$$Y = \text{sign}(\sum_{i=1}^N y_i \alpha_i K(x, x_i) + b) \quad (47)$$

využíváme odlišných jádrových funkcí K . Mezi základní jádra, řadíme lineární jádro s hranicemi vyobrazenými na Obr. 6

$$K(x_i, x_j) = x_i^T x_j \quad (48)$$

polynomiální jádro s hranicemi ilustrovanými na Obr. 7 a vyjádřené výrazem

$$K(x_i, x_j) = \tanh(\gamma x_i x_j^T + r)^d, \text{ pro } \lambda > 0. \quad (49)$$




Obr. 7 Vizualizace podpůrných vektorů s polynomiálním jádrem 3. řádu (převzato z James (2013))

Dále máme k dispozici též radiální verzi jádra

$$K(x_i, x_j) = \exp(-\gamma|x_i - x_j|^2), \text{ pro } \lambda > 0, \quad (50)$$

kde γ je šířka pásma jádra neboli s hranicí znázorněnou při klasifikaci na Obrázku 8. Lineární jádro je klasifikátorem, pro testování, zda existuje nelinearita v tréninkovém setu. Dále je vhodné jej používat jako benchmark pro otestování zlepšení klasifikace při využití nelineárních jader. Polynomiální a radiální jádro je výhodné pro modelování nelineárních hranic.



Obr. 8 Znáznornění klasifikace pro dvě skupiny pomocí nelineárního RBF jádra (převzato z James (2013))

4.3.3 Klasifikace pomocí metody rozhodovacích stromů

Rozhodovací stromy jsou nástrojem klasifikace, které vycházejí z tvorby skupin pravidel, na základě kterých se přiřazují klasifikační značky. Rozhodovací stromy založené na teorii Breimana (1993) v podtypu CART jsou produkovány pomocí algoritmu, který na základě detekovaných rozhodovacích pravidel můžeme znázornit jako různě rozvětvený binární strom. Tato metoda má výhodu v tom, že nevyžaduje platnost předpokladu o normálním rozdělení dat v tréninkové množině. Tento algoritmus začíná testováním, jehož cílem je nejkvalitnější separace klasifikovaných objektů. Obdobně jako u metody SVM využíváme dělení dat na tréninkovou, validační a testovací podmnožinu; v tomto případě ve stejné proporcii.

Data jsou rozdělena a tento postup je postupně rekurzivně aplikován na každou podskupinu s cílem dosáhnout co nejmenšího větvení nebo do bodu, kdy již nedochází ke zlepšování odhadu. Ve druhé části algoritmu procedura provádí

křížovou validaci pro získání celého stromu. Cílem je redukovat nepřesnosti předchozího kroku. Algoritmus končí, když dosáhne maximální homogenosti mezi seskupenými proměnnými pro všechny vstupní proměnné. Znázornění stromů můžeme pozorovat na schématech, například na Obrázku 23, kde vidíme způsob, jakým jsou data rozdělena podle rozhodovacích pravidel.

4.3.4 Základní vyhodnocení přesnosti klasifikace – kontingenční tabulka

Běžné ukazatele pro hodnocení kvality klasifikace jsou uvedeny v kontingenční tabulce, viz Obrázek 9. Význam vypočtených hodnot je podle Fawceta (2004):

- *Senzitivita* je poměr správně zařazených pozitivních pozorování proti všem pozitivním případům (jaký podíl skutečných případů test zachytí).
- *Specificita* je poměr správně zařazených negativních pozorování proti všem negativním případům (jaký podíl negativních případů test správně vyloučí)
- *Prevalence* – výskyt sledovaného jevu v populaci.
- Prediktivní hodnota pozitivního testu je pravděpodobnost, že případ je skutečně pozitivní, když ho test jako pozitivní vyhodnotil.
- Prediktivní hodnota negativního testu je pravděpodobnost, že případ je skutečně negativní, když jej test jako negativní vyhodnotil.

V literatuře i v naší práci je obvyklé využívat základní charakteristiky provedené klasifikace:

- Empirická průměrná míra přesnosti klasifikace

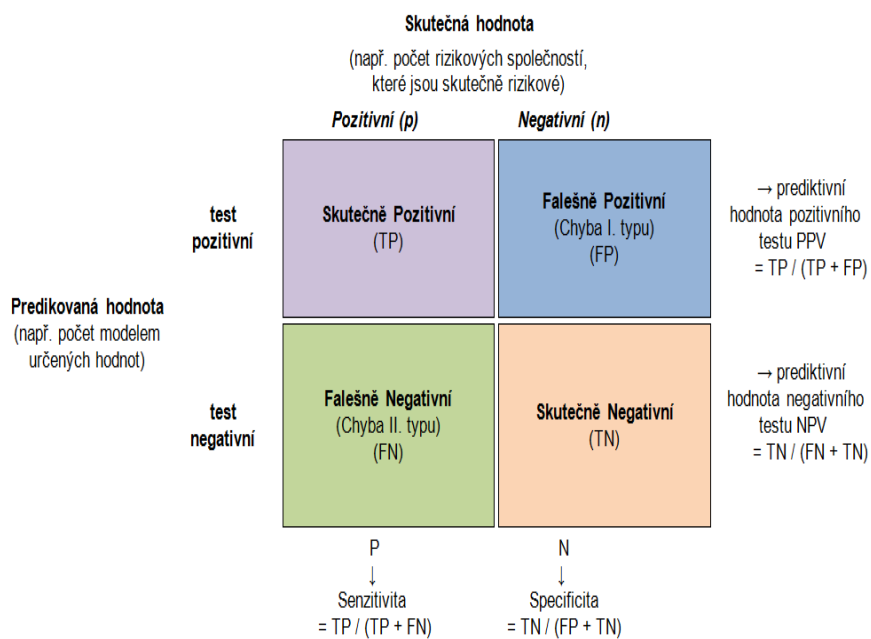
$$\text{Celková přesnost} = \frac{TP+TN}{TP+FP+FN+TN}. \quad (51)$$

- Empirická chyba prvního typu, která hodnotí počet TP, které byly klasifikované jako TN:

$$\text{Chyba I. typu} = \frac{FN}{TP+FN}. \quad (52)$$

- Dále, Chyba II. typu ukazuje kolik TN bylo označeno jako FN:

$$\text{Chyba II. typu} = \frac{FP}{FP+TN}. \quad (53)$$



Obr. 9 Kontingenční/chybová tabulka (převzato z Fawcet (2004))

5 Vlastní práce

Data, která jsou potřebná pro finanční analýzu, byla získána z dostupných informačních zdrojů. Data pro akcie společností z ČR použita k analýze pocházejí z placené sekce Patria Online, data evropských společností jsme získali z webu Yahoo Finance. Za zdroj účetních dat jsme zvolili databázi Amadeus společnosti Bureau van Dijk.

Volíme takové společnosti z řady evropských zemí, které obsahují potřebné údaje pro analýzu, tedy pro výpočet pravděpodobností finančních obtíží. Využíváme data 90 společností středně velkých a velkých akciových společností, které lze zařadit do skupiny výrobních, technologických nebo obchodních společností. Tento počet společností je zdánlivě nízký. Důvodem je, že z tisíců akciových společností měly pouze tyto společnosti komplexní a kvalitní datové údaje pro všechny potřebné roky, včetně dohledatelných kótovaných akcií s dostatečně úplnými denními daty a volatilitou.

Databáze Amadeus je zdrojem sekundárních dat, dostupné proměnné jsou uvedeny v Tabulce 47 v příloze C, vč. názvu společností. Jedná se o databázi obsahující zejména finanční data, která vycházejí z účetních výkazů a příloh k účetní závěrce, a to jak o českých, tak i evropských společnostech. V současné době tato databáze eviduje informace o stovkách tisíc ekonomických subjektů. Je zde tedy možné najít informace nejen o podnikatelských subjektech, ale rovněž o družstvech, nadacích, státních rozpočtových nebo příspěvkových organizacích. Data, ze kterých databáze vychází, jsou průběžně upravované registrační údaje těchto organizací. Základ pro získávání těchto dat tvoří zejména veřejné registry, tj. obchodní rejstřík, živnostenský rejstřík, registr ekonomických subjektů, registr plátců apod.

5.1 Základní statistické charakteristiky datového setu

Pro všechny společnosti a roky jsme spočetli základní statistické charakteristiky uvedené v Tabulkách 35 až 38 (příloha A) jako podklad pro analýzu finančních poměrových i základních ukazatelů z účetnictví v čase. Při hodnocení budeme vycházet zejména z hodnoty mediánu a dalších kvartilových ukazatelů, průměrné hodnoty nejsou podle našich zkušeností příliš objektivní ani dostatečně komplexní metrikou pro popis společnosti.

Z bližšího zkoumání dat obsažených v hodnotících tabulkách je patrné, že se v jednotlivých letech měnilo pořadí společností, resp. pořadí, ve kterém roce byly evidovány nejvyšší hodnoty apod. Nejvyšších hodnot ze všech sledovaných let ob-

ratu dosahovaly společnosti v r. 2014 pro statistiku minima a 3. kvartilu. Pro EBIT byly nejvyšší hodnoty ve všech kvartilech kromě hodnoty maxima. Hodnoty celkových aktiv, které jsou důležitým ukazatelem z hlediska čtených teorií, jsou nejvyšší pro první kvartily právě v r. 2014. Pro další ukazatele uvedené v těchto tabulkách je zobecňující hodnocení pro každý z kvartilů obtížné.

Celková zadluženost, jako základní ukazatel zadluženosti, má doporučené hodnoty mezi 30–60 %. Čím více má společnost dluhů ve vztahu k celkovým aktivům, tím je rizikovější. Jak již víme z předchozích částí, velké společnosti mohou dosáhnout na vyšší objem cizích zdrojů, tak i často mají vyšší stupeň zadlužení, než ty menší. To vše při stabilní situaci společnosti.

Koeficient samofinancování je doplňkem celkové zadluženosti – celková zadluženost vyjadřuje podíl cizích zdrojů na aktivech, koeficient samofinancování zase podíl vlastních zdrojů na aktivech.

Čím vyšší hodnoty ukazatelů rentability společnosti dosahují, tím lépe; taktéž je pozitivní pokud je viditelný rostoucí trend. Hodnota zisku zvyšuje i rentabilitu, což je z těchto podkladů evidentní. Běžná likvidita, která zohledňuje veškerá oběžná aktiva vůči krátkodobým cizím zdrojům, má doporučenou hodnotu mezi 1,5–2,5.

Doba obratu aktiv vyjadřuje dobu, po kterou jsou aktiva vázané v podniku, než se spotřebují nebo než za ně bude podnik inkasovat peníze. V odvětví analyzovaných společností je typické, že zhotovení zakázky trvá několik měsíců nebo let.

Okamžitá likvidita vyjadřuje momentální platební schopnost podniku. Jak bylo už v této práci řečeno, odborná literatura se ohledně ideálních hodnot okamžité likvidity zcela neshoduje. Pokud bychom výsledky okamžité likvidity posuzovali vzhledem k doporučenému intervalu dle Knápkové (2010), jenž je mezi 0,2 až 0,5, tak byla firma dostatečně likvidní a neměla by tedy mít problémy se splácením svých závazků. Avšak v některých publikacích jsou uváděny i jiné škály – např. Růčková (2010) doporučuje hodnoty mezi 0,6 až 1,1.

Ukazatele aktivity jsou takové, které měří schopnost firmy transformovat aktiva do peněžní nebo obchodní podoby. Slouží pro rychlé hodnocení, zda management úspěšně plní svoji roli při tvorbě obratu pomocí zdrojů. Mezi společnosti s nejvyšší hodnotou obratu v roce 2014 řadíme zejména ThyssenKrupp, Compass Group, Imperial Tobacco, Diageo, ale i společnost ČEZ. K tomu se váže i nadprůměrná hodnota EBIT nebo realizované rentability, popř. EBIT marže. Toto rozdělení je poměrně stabilní v čase pro sledovaná období let 2011 až 2014, minimálně pro 5–10 společností. Vybudovat během pár let dostatečně velkou společnost, která může z hlediska obchodního potenciálu konkurovat klíčovými hráči na trhu, je krajně nepravděpodobné.

Na druhém konci spektra jsou společnosti s nejnižším obratem, sem řadíme například Tristel, Manche, Zytronic, Pure Wafer, Goldplat, Mastrad. Stejně jako u společností s nejvyšším obratem je seskupení nízkoobratových společností v datovém setu prakticky neměnné. Ukazatel obratu však není zcela jistě tím, co společnosti přímo předurčuje k finančním obtížím – spíše naopak. Společnosti výše uvedené mají vysokou likviditu, nižší než průměrnou zadluženost, kladný výsledek hospodaření a vysoký stupeň samofinancování. Jsou tedy poměrně bezpečné, jejich nevýhodou, která brání jejich výraznějšímu růstu, je často podprůměrná rentabilita vlastního kapitálu i celkových aktiv.

Tabulka 6 slouží jako základní přehled pro to, kolik společností bylo v roce 2014 a dalších letech označeno jako rizikových. Společnosti jsou převážně z hlediska zisku nerizikové, tedy je v tomto období hodnota EBIT nezáporná. 50 z devadesáti společností je nerizikových ze strany zadluženosti, tedy mají nižší, než 50% celkovou zadluženost – u běžné likvidity je poměr přesně opačný, tedy 50 je nelikvidních. Ze strany koeficientu samofinancování je tento podíl přibližně podobný.

Tab. 6 Četnosti rizikových (R) a nerizikových (N) společností pro jednotlivé hodnotící kategorie v datovém setu pro každý ze sledovaných roků

Rizikovost	Zadluženost	Zisk	Běžná likvidita	Koeficient samofinancování
R	40	6	50	49
N	50	84	40	41

5.1.1 Shluková analýza dle finančních ukazatelů


Podkladem pro shlukovou analýzu jsou v tomto případě tzv. hlavní komponenty, které jsou výstupem analýzy PCA. Celý soubor hlavních komponent je velký jako původní datový soubor. Je zde obvyklé, že součet variance prvních několika komponent překročí 90 % celkové variability.

V našem případě volíme různý počet komponent, které vystihují více než 90% variability dat, jež popisuje Tabulka 7.

Tab. 7 Kumulovaná variabilita datového souboru

Rok	Komponenty										
	1	2	3	4	5	6	7	8	9	10	11
2011	0,27	0,45	0,59	0,68	0,76	0,83	0,89	0,92	0,95	0,98	0,99
2012	0,23	0,38	0,49	0,58	0,67	0,73	0,78	0,82	0,86	0,89	0,92
2013	0,23	0,38	0,49	0,59	0,66	0,73	0,78	0,82	0,86	0,90	0,92
2014	0,23	0,40	0,51	0,61	0,68	0,75	0,80	0,84	0,87	0,90	0,92

Počet komponent, které vstupují do shlukové analýzy je 8 u dat z roku 2014, resp. 11 pro roky 2013, 2012, 2011, což je odvozeno skrze scree plot na Obr. 49 až 52 v příloze C. V Tabulkách 39 až 41 (příloha A) jsou uvedeny proměnné a jejich vliv na variabilitu datových souborů; každá proměnná má pozitivní nebo negativní vliv, případně nebyla v komponentě přítomná. Vzhledem k rozměru dat a smíšenému vlivu v rámci komponent není možné provést detailnější analýzu pro každou z proměnných. Potřebný počet komponent jsme tedy využili jako vstupy do shlukové analýzy. Obrázky 10 až 13 znázorňují dendrogram vytvořený pomocí Wardovy metody pro analyzované roky.




Obr. 10 Dendrogram založený na účetních datech (rok 2011)

Jména všech společností jsou doplněna o označení RxN/RxN/RxN/RxN⁵, které určuje zda je společnost riziková postupně ze strany zadlužení, pohotovosti likvidity, ukazatele samofinancování a ziskovosti v minulém roce. Lze jasně pozorovat, že algoritmus na základě vektorů proměnných začlenil společnosti do shluků, které mají obdobné označení společností – zejména v případě třetího shluku z levé strany, společnosti rizikové skrze míru zadlužení i běžnou likviditu.

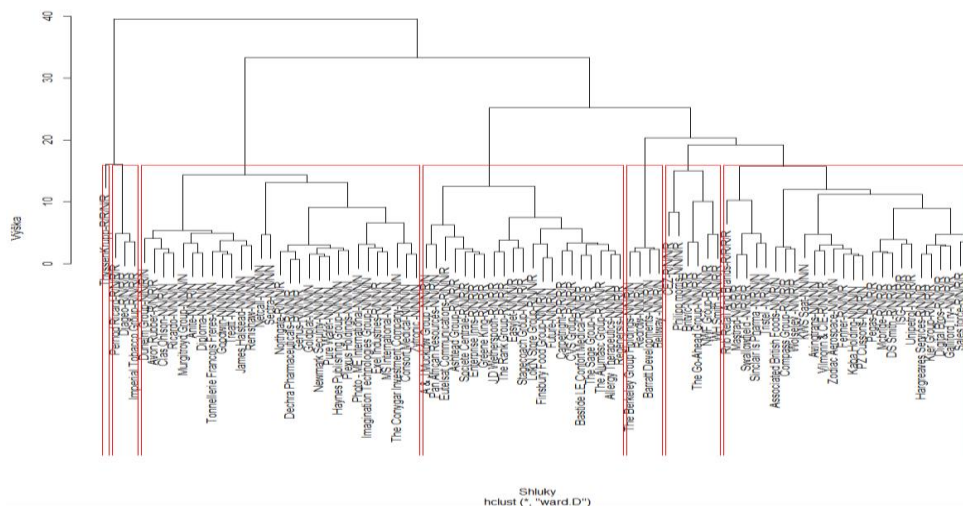
Ve 4. shluku jsou poté obsaženy společnosti s profilem N/R. I v dalších případech lze hovořit o blízkém postavení společností s podobným rizikovým profilem. To je patrné i při pohledu na původní data, kde společnosti s podobným profilem vykazují podobné finanční ukazatele v rámci vzorku dat z odvětví. U společností, které jsou rizikové – tedy zvýšeně zadlužené – můžeme pozorovat několik významných skutečností. EBIT těchto společností není převážně záporný, pouze 10 % z nich mělo v roce 2014 záporný zisk.

⁵ Písmeno R – riziková společnost, N – neriziková společnost.




Obr. 11 Dendrogram založený na účetních datech (rok 2012)

Společnosti, které jsou rizikové ze strany zadlužení, tak jsou rizikové většinou i ze strany koeficientu samofinancování. Pomocí účetních dat klasifikujeme společnosti do shluků, kde je v roce 2012 viditelné, že v prvním shluku zleva a zprava jsou označeny společnosti s nejrizikovějším profilem. V centrální části jsou pak obsaženy společnosti, které se vzájemně méně liší, přičemž ve druhém a třetím a čtvrtém shluku jsou firmy převážně nerizikové. Shlukování společností v letech 2013 a 2014 lze hodnotit podobně jako předchozím období, shlukování poměrně přesně rozpoznává firmy, jejichž finanční profil je podobný. To znamená, že společnosti rizikové náležejí k bližším nebo vzájemně stejným shlukům.



Obr. 12 Dendrogram založený na účetních datech (rok 2013)

Otázka redukce počtu proměnných je v našem případě velmi problematická, jak vyplývá z našeho předchozího výzkumu na základě statistického hodnocení proměnných, viz Klepáč a Hampel (2015).



Obr. 13 Dendrogram založený na účetních datech (rok 2014)

5.2 Odhad finanční situace společností pomocí účetních modelů

5.2.1 Altmanův a Ohlsonův model

Po dosazení proměnných do jednotlivých modelů můžeme hodnotit pravděpodobnosti finančního zdraví společností, viz Tabulka 8. Hodnoty pro každou ze společností vidíme v Tabulkách 48 a 49 v příloze C.

Tab. 8 Základní průměrné statistické charakteristiky pravděpodobností finančních obtíží dle Altmanova a Ohlsonova modelu

Statistika	Ohlsonův model				Altmanův model			
	2014	2013	2012	2011	2014	2013	2012	2011
Minimum	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
1. kvartil	2,08%	2,18%	2,04%	2,32%	1,00%	2,00%	2,00%	2,00%
Medián	5,62%	5,07%	5,36%	5,42%	5,00%	5,00%	6,00%	6,00%
3. kvartil	22,27%	14,18%	16,52%	14,81%	11,00%	11,00%	12,00%	11,00%
Maximum	100,00%	66,15%	73,30%	99,92%	100,00%	100,00%	100,00%	100,00%

Pravděpodobnosti finančního ohrožení jsou mezi modely odlišné, přesněji minimální hodnoty jsou nižší u Altmanova modelu než u Ohlsonova modelu – to platí pro všechny sledované roky. Pro první kvartil již platí opačný jev, avšak pro hodnoty mediánu jsou výsledky různorodější, kdy pouze v roce 2014 Ohlsonův model poskytoval vyšší pravděpodobnosti než Altmanův model. Na 3. kvartilu již vidíme, že pravděpodobnosti v rámci datového setu jsou u Ohlsonova modelu vyšší. Maxi-

mální hodnoty blízko 1 jsou pro sledované období konzistentní pouze u Altmanova modelu, pro roky 2012 a 2013 jsou tyto údaje u Ohlsonova modelu nižší.

Tab. 9 Základní průměrná statistická skóre dle Altmanova a Ohlsonova modelu

Statistika	Ohlsonův model				Altmanův model			
	2014	2013	2012	2011	2014	2013	2012	2011
Minimum	-113,24	-6,19	-7,27	-40,87	-24,8	-17,48	-7,25	-17,39
1. kvartil	-3,85	-3,8	-3,87	-3,74	2,28	2,21	2,18	1,28
Medián	-2,82	-2,93	-2,87	-2,86	3,06	2,93	2,86	1,81
3. kvartil	-1,25	-1,8	-1,62	-1,75	4,38	4,19	3,81	2,4
Maximum	31,54	0,67	1,01	7,08	62,67	72,92	83,41	71,07

Při hodnocení vývoje rizikovosti úpadku sledujeme, že s blížícím se rokem 2014 se zvyšovala pravděpodobnost finančních obtíží v rámci datového souboru – pro Ohlsonův model. Jednotlivé dendrogramy vidíme zobrazené na Obrázcích 41 až 48 v příloze B spolu s korespondujícími značkami R/N. Pro lepší názornost vždy srovnáváme dendrogramy ve stejných letech. Jak víme, tak dělící hranice pro krizovou, bezpečnou, resp. neutrální zónu jsou

- $3,00 < Z$ – Bezpečná zóna (Safe Zone) – podniky s vysokou pravděpodobností přežití;
- $1,81 < Z < 2,99$ – Šedá zóna (Grey Zone) – nelze určit stav společnosti;
- $Z < 1,81$ Krizová zóna (Distress Zone) – podniky ohrožené bankrotem v následujících několika letech.

Pokud je hodnota Z vyšší jak 2,99, můžeme o firmě říci, že má uspokojivou finanční situaci. Pokud index klesne pod 1,81, má firma velmi silné finanční problémy. Pokud se firma nachází v rozmezí od 1,81 do 2,99, hovoříme o nevyhraněné finanční situaci, tzv. šedé zóně. Z hodnot v Tabulkách 8 (přepočtená pravděpodobnost) a 9 (základní skóre) uvedených výše můžeme odvodit, že ještě na mediánu datového souboru jsou společnosti takřka finančně zdravé, ačkoliv v období před rokem 2012 tomu tak zjevně nebylo. Došlo ke zlepšení finanční situace společností. Na úrovni prvního kvartilu jsou společnosti stále v šedé zóně, nejnižší hodnoty jsou poté již záporné. I přes domněle znepokojivou situaci společností v roce 2011 však ani u nich nedošlo k bankrotu, je tedy možné, že management společností zareagoval na tyto skutečnosti a zvrátil nepříznivou predikci firemní budoucnost. Ve srovnání jsou i společnosti, které by měly podle účetních modelů zbankrotovat, ale nestalo se tak.

Pro Ohlsonův model platí, že bankrotem jsou ohroženy společnosti s O -skóre vyšším, než 0; těm je přiřazena pravděpodobnost bankrotu vyšší, než 50 % – tj.

bankrotní profil. Vzhledem k nastavení výpočtů nejsou společnosti se záporným O-skóre ohrožené bankrotem.

Mezi společnosti s nejvyšší hodnotou Altmanova skóre se ve všech letech řadí společnosti Sales Force, Avon Rubber, Clas Ohlson, Imagination Technologies Group, Diploma, Renishaw, Zytronic. Tyto firmy se vyznačují, tím že mají nadprůměrné hodnoty rentability ROA i ROE, podprůměrný obrat dluhu, výši čistého pracovního kapitálu nižší – podprůměrný poměr mezi fixním a celkovými aktivy. Kromě společnosti Sales Force, Avon Rubber a Clas Ohlson se jedná o společnosti nadprůměrné likvidní. Můžeme tedy říct, že Altmanův model upřednostňuje v našem případě společnosti s vysokou rentabilitou, jelikož se jedná o klíčový ukazatel, který vstupuje do Z-skóre. Z dalších skutečností je zajímavé, že společnosti s nejvyšším skóre jsou spíše menší ve smyslu obratu a hodnoty EBIT.

Při srovnání s hodnotami Ohlsonova modelu vidíme, že vysoké úrovně v Altmanově modelu predeterminují i vysokou kvalitu společností přes Ohlsonův model, tedy kromě společností Avon Rubber a Salesforce.

Tato vazba mezi O a Z-skóre funguje i naopak. Společnosti kvalitní podle O-skóre fungují jako prekurzor i pro Altmanův model, s tím rozdílem, že stabilní společnosti mají nadprůměrnou rentabilitu, jsou minimálně ve stavu šedé zóny, resp. finančně zdravé u Altmanova modelu.

Jejich obrat nebo EBIT je v mnoha případech nadprůměrný – je zde i vazba na to, zda společnosti využívají dlouhodobých a ne krátkodobých finančních zdrojů. Společnosti jsou také více likvidní, než v případě Altmanova modelu. S tím je spojen i vyšší koeficient samofinancování, což společnosti činí ještě stabilnější. To platí pro všechny roky zkoumání.

Při pohledu do Tabulky 10, kde je zřetelné, že nejlepší společnosti jsou častěji klasifikovány jako nerizikové v případě Ohlsonova modelu, než u modelu Altmanova.

Tab. 10 Přiřazení rizikových značek u 20 nejlepších společností podle O-skóre nebo Z-skóre

Rok 2012	Zadluženost	Zisk	Běžná likvidita	Koef. samofinancování
Altmanův model	5	0	9	5
Ohlsonův model	2	0	10	3
Rok 2013	Zadluženost	Zisk	Běžná likvidita	Koef. samofinancování
Altmanův model	4	0	7	4
Ohlsonův model	2	0	9	3
Rok 2014	Zadluženost	Zisk	Běžná likvidita	Koef. samofinancování
Altmanův model	4	0	7	5
Ohlsonův model	2	0	7	2

V návaznosti na Tabulku 10 a text uvedený výše zobrazujeme detailní pohled na 20 společností s nejnižšími hodnotami pravděpodobnostmi úpadku podle Altmanova i Ohlsonova modelu. Ke každé z těchto 20 společností je pro shlukované proměnné pro klasifikaci proměnných přiřazena značka R (riziková) nebo N (neriziková), viz Tabulky 11 až 15.

Tab. 11 20 nejméně rizikových společností podle Altmanova modelu (rok 2012)

Společnosti	Altmanův m.	Ohlsonův m.	O. pvst	A. pvst	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
Avon Rubber	83,41	-1,90	13,10%	0,00%	R	N	R	R
Sales force	35,28	0,21	55,10%	0,00%	R	N	R	R
MS International	30,24	-4,58	1,00%	0,00%	N	N	N	N
Imagination Technologies G.	20,79	-6,14	0,20%	0,00%	N	N	N	N
Clas Ohlson	14,45	-3,79	2,20%	0,00%	N	N	R	N
Sectra	8,16	-7,27	0,10%	0,00%	N	N	N	N
Renishaw	8,04	-5,76	0,30%	0,00%	N	N	N	N
Dunelm Group	7,40	-5,29	0,50%	0,10%	N	N	R	N
James Halstead	6,84	-4,84	0,80%	0,10%	N	N	N	N
Diploma	6,25	-4,67	0,90%	0,20%	N	N	N	N
Tristel	5,69	-3,95	1,90%	0,30%	N	N	N	N
Pan African Resources	5,62	-5,85	0,30%	0,40%	N	N	R	N
NWF Group	5,57	-0,50	37,80%	0,40%	R	N	N	R
WH Smith	5,50	-4,66	1,40%	0,40%	R	N	R	R
Zytronic	5,20	-3,86	2,10%	0,50%	N	N	N	N
The Rank Group	4,30	-4,35	1,30%	1,30%	R	N	R	R
PZ Cussons	4,28	-1,63	16,40%	1,40%	N	N	R	N
Murgitroyd Group	4,06	-3,30	3,60%	1,70%	N	N	N	N
Kaba Holding	4,04	-3,87	2,00%	1,70%	N	N	N	N
Treatt	3,98	-2,82	5,60%	1,80%	N	N	R	N

Tab. 12 20 nejméně rizikových společností podle Ohlsonova modelu (rok 2012)

Společnosti	Altmanův m.	Ohlsonův m.	O. pvst	A. pvst	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
Sectra	8,16	-7,27	0,10%	0,00%	N	N	N	N
Imagination Technologies Group	20,79	-6,14	0,20%	0,00%	N	N	N	N
Bellway	3,71	-6,13	0,20%	2,40%	N	N	R	N
Pan African Resources	5,62	-5,85	0,30%	0,40%	N	N	R	N
Renishaw	8,04	-5,76	0,30%	0,00%	N	N	N	N
Barratt Developments	2,16	-5,39	0,50%	10,30%	N	N	R	N
Goldplat	3,37	-5,30	0,50%	3,30%	N	N	N	N
Dunelm Group	7,40	-5,29	0,50%	0,10%	N	N	R	N
Redrow	2,97	-5,02	0,70%	4,90%	N	N	R	N
James Halstead	6,84	-4,84	0,80%	0,10%	N	N	N	N

Associated British Foods	3,73	-4,82	0,80%	2,30%	N	N	R	N
Diploma	6,25	-4,67	0,90%	0,20%	N	N	N	N
WH Smith	5,50	-4,66	1,40%	0,40%	R	N	R	R
The Berkeley Group Holdings	3,66	-4,64	1,00%	2,50%	N	N	R	R
MS International	30,24	-4,58	1,00%	0,00%	N	N	N	N
Tonnellerie Francois Freres	2,56	-4,51	1,10%	7,20%	N	N	N	N
The Rank Group	4,30	-4,35	1,30%	1,30%	R	N	R	R
KWS Saat	3,70	-4,22	1,50%	2,40%	N	N	N	N
Zodiac Aerospace	2,81	-4,09	1,60%	5,70%	N	N	R	N
Tristel	5,69	-3,95	1,90%	0,30%	N	N	N	N

Tab. 13 20 nejméně rizikových společností podle Altmanova modelu (rok 2013)

Společnosti	Altmanův m.	Ohlsonův m.	O. pvst	A. pvst	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
Avon Rubber	72,92	-1,46	18,90%	0,00%	R	N	R	R
Sales force	48,99	-0,24	44,00%	0,00%	R	N	R	R
Clas Ohlson	13,59	-3,66	2,50%	0,00%	N	N	R	N
Dunelm Group	9,62	-5,20	0,50%	0,00%	N	N	R	N
Diploma	9,46	-4,95	0,70%	0,00%	N	N	N	N
Imagination Technologies Group	8,36	-4,19	1,50%	0,00%	N	N	N	N
Renishaw	8,24	-6,04	0,20%	0,00%	N	N	N	N
Zytronic	8,24	-3,81	2,20%	0,00%	N	N	N	N
Plexus Holdings	8,12	-3,80	2,20%	0,00%	N	N	N	N
James Halstead	7,38	-4,55	1,00%	0,10%	N	N	N	N
Sectra	6,22	-4,36	1,30%	0,20%	N	N	N	N
WH Smith	5,77	-2,25	9,50%	0,30%	R	N	R	R
MS International	5,67	-2,85	5,50%	0,30%	N	N	N	N
Consort Medical	5,57	-4,05	1,70%	0,40%	N	N	N	N
NWF Group	5,55	-0,59	35,70%	0,40%	R	N	N	R
Murgitroyd Group	4,85	-3,80	2,20%	0,80%	N	N	N	N
Tristel	4,59	-3,63	2,60%	1,00%	N	N	N	N
Anite	4,49	-2,98	4,80%	1,10%	N	N	N	N
Bellway	4,44	-6,19	0,20%	1,20%	N	N	R	N
Associated British Foods	4,42	-5,00	0,70%	1,20%	N	N	R	N

Tab. 14 20 nejméně rizikových společností podle Ohlsonova modelu (rok 2013)

Společnosti	Altmanův m.	Ohlsonův m.	O. pvst	A. pvst	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
-------------	-------------	-------------	---------	---------	-------------	------	-----------------	--------------

Bellway	4,44	-6,19	0,20%	1,20%	N	N	R	N
Renishaw	8,24	-6,04	0,20%	0,00%	N	N	N	N
Barratt Developments	2,40	-5,33	0,50%	8,30%	N	N	R	N
Dunelm Group	9,62	-5,20	0,50%	0,00%	N	N	R	N
Associated British Foods	4,42	-5,00	0,70%	1,20%	N	N	R	N
Diploma	9,46	-4,95	0,70%	0,00%	N	N	N	N
The Berkeley Group Holdings	3,95	-4,89	0,70%	1,90%	N	N	R	R
Redrow	2,95	-4,80	0,80%	5,00%	N	N	R	N
Tonnellerie Francois Freres	2,93	-4,56	1,00%	5,10%	N	N	N	N
James Halstead	7,38	-4,55	1,00%	0,10%	N	N	N	N
Photo - ME International	3,20	-4,47	1,10%	3,90%	N	N	N	N
Pan African Resources	3,00	-4,45	1,20%	4,70%	N	N	R	N
Zodiac Aerospace	3,25	-4,36	1,30%	3,80%	N	N	R	N
Sectra	6,22	-4,36	1,30%	0,20%	N	N	N	N
Genus	2,94	-4,26	1,40%	5,00%	R	N	N	R
Imagination Technologies Group	8,36	-4,19	1,50%	0,00%	N	N	N	N
Kaba Holding	4,00	-4,15	1,60%	1,80%	N	N	N	N
KWS Saat	3,87	-4,14	1,60%	2,10%	N	N	N	N
Consort Medical	5,57	-4,05	1,70%	0,40%	N	N	N	N
Pernod Ricard	1,92	-3,94	1,90%	12,80%	R	N	R	R

Tab. 15 20 nejméně rizikových společností podle Altmanova modelu (rok 2014)

Společnosti	Altmanův m.	Ohlsonův m.	O. pvst	A. pvst	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
Sales force	62,67	-0,45	38,90%	0,00%	0,014	R	N	R
Avon Rubber	61,29	-1,92	12,80%	0,00%	0,081	R	N	R
Clas Ohlson	14,21	-3,67	2,50%	0,00%	0,039	N	N	R
Plexus Holdings	11,13	0,78	68,60%	0,00%	0,062	N	N	N
Diploma	10,07	-4,96	0,70%	0,00%	0,013	N	N	N
Renishaw	8,37	-6,96	0,10%	0,00%	0,017	N	N	N
Imagination Technologies Group	8,23	-5,59	0,40%	0,00%	0,018	N	N	N
James Halstead	7,24	-5,23	0,00%	0,10%	0,018	N	N	N
Consort Medical	6,66	-4,75	0,90%	0,10%	0,038	N	N	N
Sectra	6,47	-4,46	1,10%	0,20%	0,019	N	N	N
WH Smith	6,13	-0,99	27,00%	0,20%	0,016	R	N	R
Murgitroyd Group	5,76	-4,01	1,80%	0,30%	0,02	N	N	N
NWF Group	5,57	-0,87	29,50%	0,40%	0,019	R	N	N

Dechra Pharmaceuticals	5,53	-4,09	1,70%	0,40%	0,035	N	N	N
Associated British Foods	4,99	-5,19	0,60%	0,70%	0,016	N	N	R
Goodwin	4,92	-3,67	2,50%	0,70%	0,012	N	N	N
Zytronic	4,59	-6,00	0,20%	1,00%	0,017	N	N	N
Treant	4,49	-2,95	5,00%	1,10%	0,016	N	N	R
Wolseley	4,46	-3,83	2,10%	1,10%	0,017	N	N	R
Photo - ME International	4,46	-2,05	11,40%	1,10%	0,022	N	N	N

Tab. 16 20 nejméně rizikových společností podle Ohlsonova modelu (rok 2014)

Společnosti	Altmanův m.	Ohlsonův m.	O. pvst	A. pvst	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
James Halstead	7,24	-113,23	0,00%	0,10%	N	N	N	N
Hargreaves Services	4,33	-7,18	0,10%	1,30%	R	N	N	R
Renishaw	8,37	-6,96	0,10%	0,00%	N	N	N	N
Regeneris	2,30	-6,10	0,20%	9,10%	N	N	N	N
Bellway	4,46	-6,02	0,20%	1,10%	N	N	R	N
Zytronic	4,59	-6,00	0,20%	1,00%	N	N	N	N
Barratt Developments	3,08	-5,80	0,30%	4,40%	N	N	R	N
Imagination Technologies Group	8,23	-5,59	0,40%	0,00%	N	N	N	N
Associated British Foods	4,99	-5,19	0,60%	0,70%	N	N	R	N
Dunelm Group	4,38	-5,19	0,60%	1,20%	N	N	R	N
Diploma	10,07	-4,96	0,70%	0,00%	N	N	N	N
Redrow	3,35	-4,77	0,80%	3,40%	N	N	R	N
Consort Medical	6,66	-4,75	0,90%	0,10%	N	N	N	N
Tonnellerie Francois Freres	3,56	-4,75	0,90%	2,80%	N	N	N	N
Sectra	6,47	-4,46	1,10%	0,20%	N	N	N	N
Kaba Holding	4,20	-4,25	1,40%	1,50%	N	N	N	N
Zodiac Aerospace	3,38	-4,21	1,50%	3,30%	N	N	R	N
Pernod Ricard	1,94	-4,13	1,60%	12,60%	R	N	R	R
Dechra Pharmaceuticals	5,53	-4,09	1,70%	0,40%	N	N	N	N
Netcall	3,50	-4,08	1,70%	2,90%	N	N	N	N

5.3 Odhad pravděpodobnosti defaultu pomocí strukturálních modelů rizika

Pro výpočet rizikových ukazatelů pomocí strukturálních modelů rizika využíváme postup uvedený v podčásti metodiky práce. Při odhadu pravděpodobnosti defaultu⁶ skrze Mertonův využíváme proměnné, které nám dále poslouží ke klasifikaci v následujících částech práce. Nyní si připomeneme kroky a nutné použité proměnné vstupující do výpočtů, vypočtené údaje jsou obsažené v Tabulkách 43 až 45 (příloha C)

- Odhad anualizované volatility vlastního kapitálu.
- Tržní kapitalizace společnosti jako násobek počtu akcií a jejich tržní hodnoty, pro určený časový okamžik.
- Bezriziková úroková sazba zemí EU.
- Délka splatnosti dluhopisu – jelikož nás zajímá odhad pravděpodobnosti defaultu ve střednědobém horizontu, volíme v tomto případě pětiletý horizont.
- Výše defaultní bariéry – v našem případě využíváme hodnoty ve výši krátkodobých závazků a jedné poloviny dlouhodobých závazků.
- Hodnota volatility aktiv společnosti – hodnota získaná ze systému rovnic (24) a (25).
- Tržní hodnota aktiv – hodnota získaná ze systému rovnic uvedeného v rovnicích (24) a (25).

5.3.1 Odhady volatility a přiřazení rizika

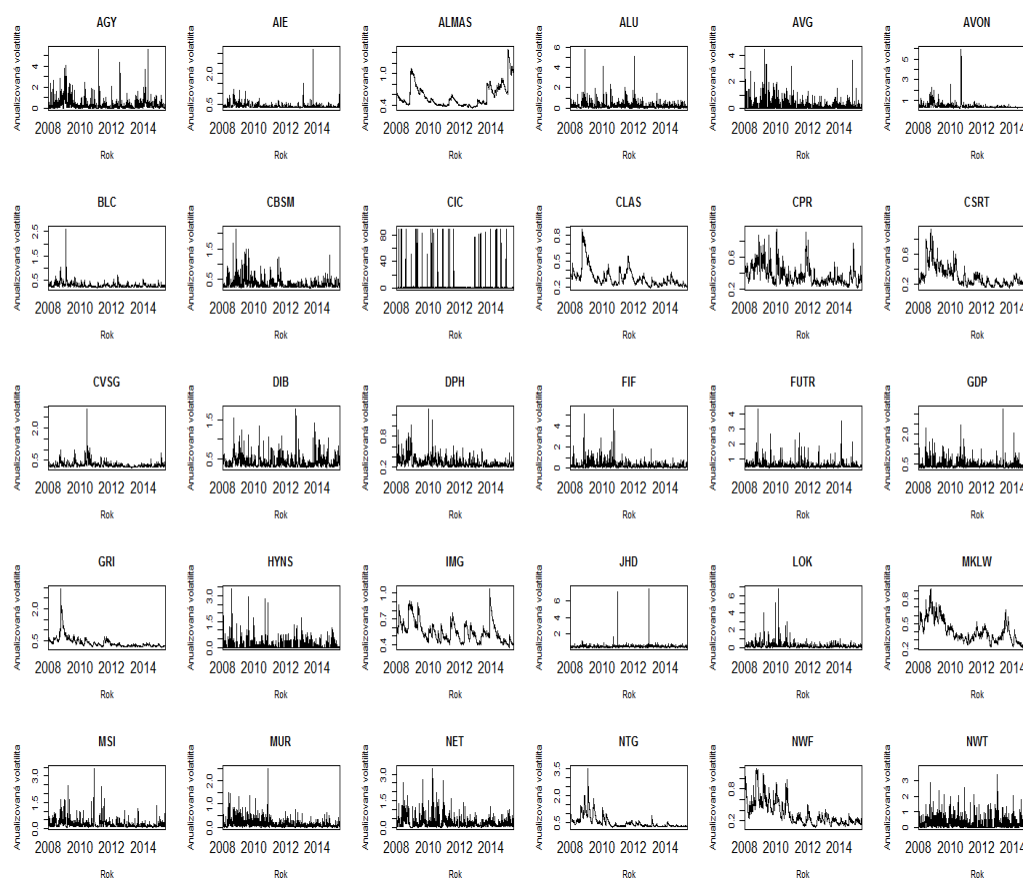
Pomocí modelů volatility potenciálně zachycujeme období s výraznými tržními výkyvy. Na většině grafů pro všechny sledované společnosti proto můžeme pozorovat období s mírným kolísáním v čase a období s občasnými většími oscilacemi – kdy hodnota volatility přesahuje dokonce hodnotu 1 nebo dokonce 5. Průměrné statistické hodnoty akciových výnosů pro všechny společnosti jsou obsaženy v Tabulce 17.

⁶ U strukturálních modelů rizika se držíme teorie, která zahrnuje pojem default, avšak využíváme tyto modely i pro odhad rizika nebo stavu společnosti, které korespondují s uměle odhadnutou hladinou rizikivosti tedy ne nutně defaultní situací.

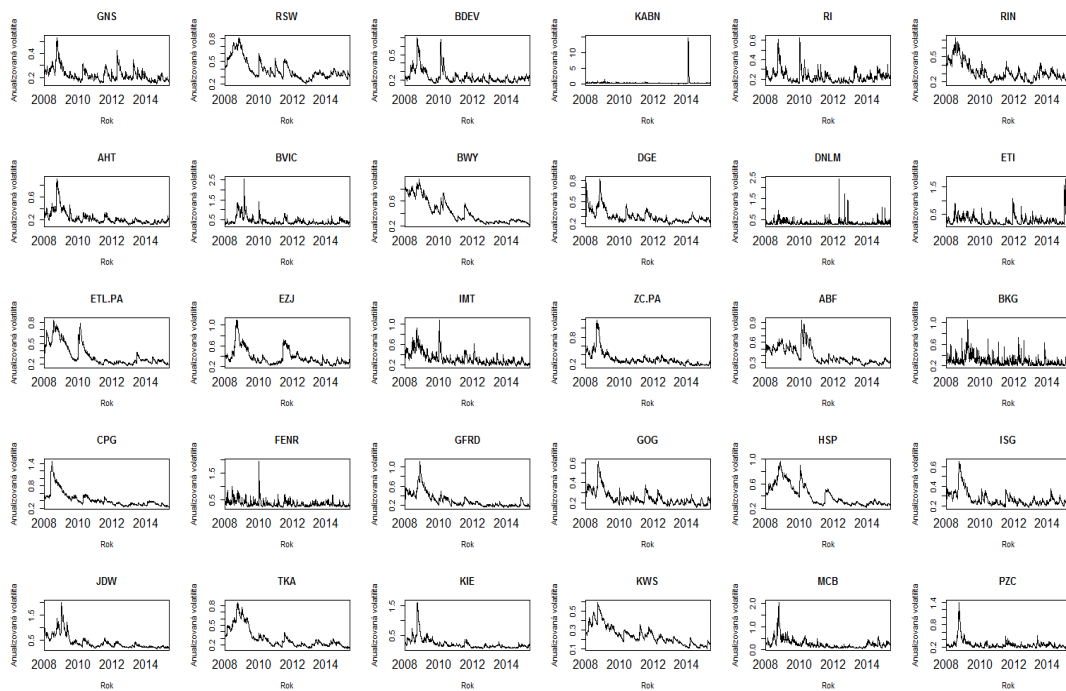
Tab. 17 Základní průměrné statistické charakteristiky pro denní výnosy

Průměry výnosů	2008	2009	2010	2011	2012	2013	2014
Minimum	-0,211	-0,173	-0,249	-0,184	-0,074	-0,145	-0,174
1. kvartil	-0,017	-0,012	-0,009	-0,010	-0,007	-0,007	-0,008
Medián	-0,002	0,000	0,000	0,000	0,000	0,000	0,000
3. kvartil	0,013	0,014	0,009	0,009	0,008	0,008	0,008
Maximum	0,176	0,261	0,243	0,190	0,082	0,167	0,130

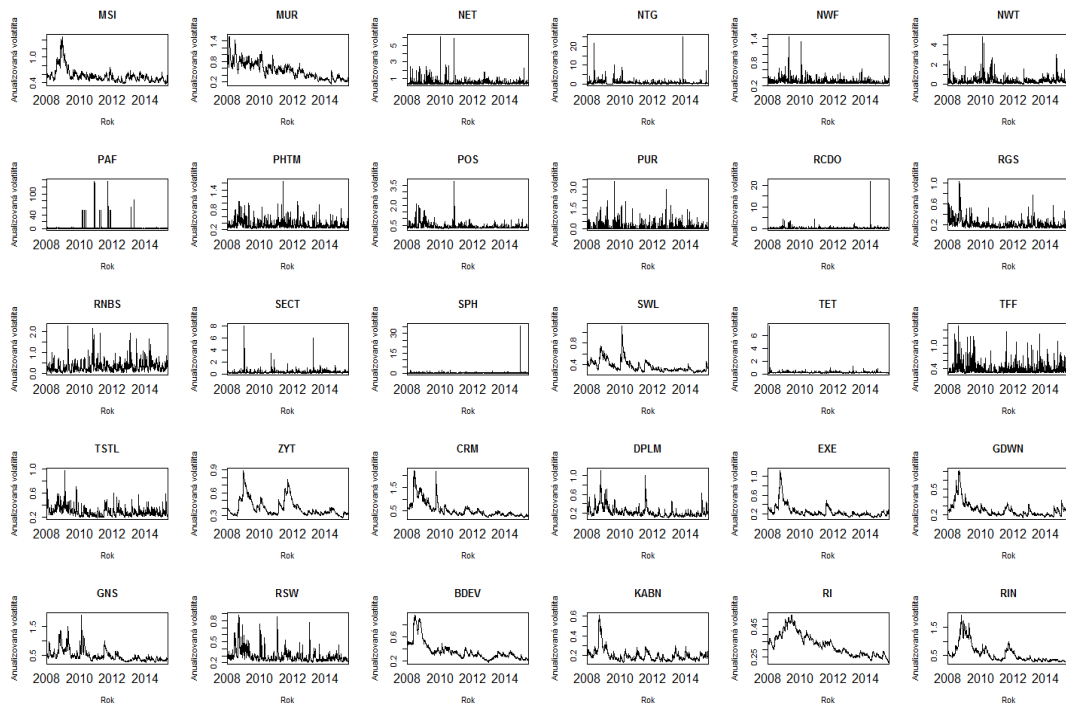
Volatilitu lze vyjádřit v základní (denní) podobě, což odpovídá charakteru vstupních denních dat. V našem případě využíváme roční, tedy přepočtenou volatilitu, která dále vstupuje do výpočtů v rámci strukturálních modelů pro zvolená období, viz Obrázky 14 až 16.



Obr. 14 Odhad volatilitu pro období 2008 až 2015 (30 společností, popis zkratk společností je obsažen v Tab. 50)



Obr. 15 Odhad volatility pro období 2008 až 2015 (30 společností, popis zkratek společností je obsažen v Tab. 50)



Obr. 16 Odhad volatility pro období 2008 až 2015 (30 společností, popis zkratek společností je obsažen v Tab. 50)

V následujícím textu uvádíme shrnutí výsledků pro vstupní roky společností. V příloze C, přesněji v Tabulce 43 až 45 jsou obsaženy hodnoty průměrné anualizované volatility pro každou ze společností pro vstupní roky do odhadu rizika u strukturálních modelů – jedná se průměry s vždy o rok zázším intervalem měření. Základní statistiky jsou obsaženy v Tabulce 18.

Tab. 18 Základní statistické charakteristiky anualizované volatility (v letech 2012 až 2014, 100% je rozptyl = 1)

Statistika	2012	2013	2014
Minimum	10,1%	9,7%	9,6%
1. kvartil	30,3%	28,3%	27,2%
Median	37,3%	35,6%	33,0%
3. kvartil	47,6%	44,6%	43,2%
Maximum	328,7%	267,6%	283,1%
Průměr	44,6%	41,0%	39,2%

Při bližším pohledu na charakteristiky zjištěné anualizované volatility nemůžeme říct, že by byly společnosti s nejvyšší volatilitou také ty nejrizikovější – ačkoliv zde převládá tendence, že takové společnosti jsou označeny alespoň jedním „R“. Společnosti s nejvyšší volatilitou jsou tedy vesměs spíše dynamické, než extrémně předlužené nebo nelikvidní, což se projevuje i ve finančních výkazech. Některé z těchto společností jako The Conygar Investment Company, Pure Wafer, Barratt Developments jsou naopak nadprůměrně rentabilní nebo bonitní ve všech letech.

Společnosti jako jsou Mastrad, Carpetright nebo Bastide LE Confort Medical jsou ve sledovaných obdobích ve špatné finanční situaci, nadprůměrným zadlužením i nízkou krátkodobou likviditou, resp. záporným EBIT. Společnosti s vysokou likviditou mají oproti ostatním v převážné většině v letech 2013 a 2014 naprůměrný podíl fixních aktiv k celkovým, přes 54 %.

Tab. 19 20 společností s nejvolatilnějšími akciemi a jejich vztah k rizikovým značkám v roce 2014

Společnost	Volatilita	Zadluženost	Zisk	Běžná likvidita	Koef. samofin.
The Conygar Investment Company	328,7%	N	N	N	N
Future	63,8%	N	R	R	R
Avon Rubber	62,1%	R	N	R	R
Grainger	55,7%	R	N	N	R
Mastrad	51,3%	R	R	R	R
Goldplat	46,2%	N	N	N	N
Anite	43,7%	N	N	N	N

Carpentright	43,7%	R	R	R	R
Digital Bros	42,4%	R	N	N	R
Societe Centrale	39,8%	R	N	R	R
CVS Group	37,3%	R	N	R	R
Clas Ohlson	37,0%	N	N	R	N
Consort Medical	36,1%	N	N	N	N
Allergy Therapeutics	35,7%	N	N	N	N
Dechra Pharmaceuticals	35,2%	N	N	N	N
Bastide LE Confort Medical	33,8%	R	N	R	R
Finsbury Food Group	33,8%	N	N	R	N
Northgate	27,7%	R	N	N	R
J D Wetherspoon	27,4%	R	N	R	R
Newmark Security	27,2%	N	N	N	N

Pro účely vizualizace a lepšího pochopení pozice ostatních společností ze strany volatility volíme i zde zobrazení pomocí dendrogramů, viz Obrázky 29 až 31 v příloze B. Společnost The Conygar Investment Company stojí kvůli své velmi vysoké analizované volatilitě osamoceně ve struktuře. Využití volatility ke klasifikaci není při bližším pohledu na dendrogram uspokojivé, rozčlenění společností nekoreponduje se značkami.

Tab. 20 20 společností s nejvolatilnějšími akciemi a jejich vztah k rizikovým značkám v roce 2013

Společnost	Volatilita	Zadluženost	Zisk	Běžná likvidita	Koef. samofin.
The Conygar Investment Company	267,6%	N	N	N	N
Rnb Retail And Brands	261,6%	R	R	R	R
Pure Wafer	71,9%	N	N	N	N
Enterprise Inns	67,8%	R	N	R	R
PhotoME International	66,8%	N	N	N	N
Barratt Developments	66,3%	N	N	R	N
Northgate	63,1%	R	N	N	R
Pan African Resources	60,6%	N	N	R	N
Future	60,5%	N	R	R	R
Imagination Technologies Group	60,0%	N	N	N	N
Ashtead Group	57,9%	R	N	R	R
Avon Rubber	55,6%	R	N	R	R
Galliford Try	51,3%	N	N	R	R
Wolseley	50,4%	N	N	R	R

Fenner	50,1%	R	N	N	R
Grainger	49,8%	R	N	N	R
Redrow	49,1%	N	N	R	N
DS Smith	48,5%	R	N	R	R
Mastrad	46,9%	R	R	R	R
Goldplat	45,1%	N	N	N	N

V mnoha případech se smíšeně rizikové společnosti shlukují blízko společností zcela nerizikových. Přesto lze vysledovat v datech určité rozdělení společností – v rozmezí 25–35 % okolo hranic 45–55 % v rámci jednoho roku jsou společnosti rizikové více často, než ty mimo tento interval. Týká se to například společností jako je ČEZ, Pernord Ricard, Netcall, Unipetrol, The Sage Group nebo dříve jmenovaných společností s volatilitou okolo 50 %: Northgate, Future, Fenner, Grainger, Avon Rubber apod.

Tab. 21 20 společností s nejvolatilnějšími akciemi a jejich vztah k rizikovým značkám v roce 2012

Společnost	Volatilita	Zadluženost	Zisk	Běžná likvidita	Koef. samofin.
The Conygar Investment Company	283,1%	N	N	N	N
Rnb Retail And Brands	239,0%	R	R	R	R
Pure Wafer	73,4%	N	N	N	N
Enterprise Inns	61,7%	R	N	R	R
Barratt Developments	61,2%	N	N	R	N
Photo-ME International	61,1%	N	N	N	N
Pan African Resources	59,6%	N	N	R	N
Imagination Technologies Group	58,8%	N	N	N	N
Northgate	57,9%	R	N	N	R
Future	57,7%	N	R	R	R
Ashtead Group	53,9%	R	N	R	R
Avon Rubber	51,3%	R	N	R	R
Fenner	47,0%	R	N	N	R
Mastrad	46,7%	R	R	R	R
Galliford Try	46,5%	N	N	R	R
Grainger	46,1%	R	N	N	R
Wolseley	46,0%	N	N	R	R
Redrow	46,0%	N	N	R	N
DS Smith	44,6%	R	N	R	R
Goldplat	44,5%	N	N	N	N

5.3.1 Odhad D-Vine kopula GARCH modelů

Finální model, který využíváme k získání reziduí pro modelování vícerozměrných závislostí je znám již z našich předchozích publikací Klepáč a Hampel (2015), kde provádíme důkladné srovnání se zobecněnými výsledky pomocí typů EGARCH, APARCH, iGARCH apod. Pro modelování akciových výnosů se nejvíce osvědčil nelineární model volatility ARMA(1,1)-GARCH(1,1)-GJR se Studentovým t-rozdělením, který byl podroben mnohým testováním a výběru na základě minimalizace hodnot informačních kritérií, jak bylo uvedeno taktéž v metodice práce. Řídíme se základními kroky dle Aas a kol. (2009). Nejprve provedeme filtrování dat pomocí ARMA(1,1) modelu, rezidua standardizujeme pomocí odhadnuté volatility, dále transformujeme výsledné hodnoty do tvaru uniformně rozdělených dat na intervalu (0,1) pomocí SW Matlab.

Po základním hodnocení volatility společností v čase přecházíme k odhadům a selekci vhodných kopula funkcí, které dále vstoupí do predikce rizika. V případě D-Vine kopulí modelujeme závislost mezi prvky, které jsou na stejné úrovni závislosti. Po základní filtraci dat pomocí ARMA-GARCH modelu, jejich standardizaci a transformaci do kopula tvaru dat (interval hodnoty 0 až 1) vycházíme z již uvedených kroků:

- Zhodnocení pomocí podle informačních kritérií pro stanovení nejvhodnějších kopula funkcí pro určení struktury závislosti mezi rezidui.
- Odhad kopula parametrů pomocí metody maximální věrohodnosti (MLE), kdy využíváme dostupné kopule s jedním nebo dvěma parametry uvedené v Tabulce 4.
- Simulace z D-Vine kopula rozdělení, v našem případě generujeme 10 tisíc identicky rozdělených čísel pro všech 90 společností, které dále zpracováváme do určení terminální hodnoty tržní hodnoty aktiv pro vyhodnocení, zda společnosti zdefaultují nebo nikoliv.
- Z celkových výsledků simulace odvozujeme pravděpodobnosti realizace uvedených jevů pro všechny společnosti.

Pro odhad Vine kopulí a jejich závislostí musíme stanovit charakter této závislosti, tedy rodinu kopula funkcí pro vícerozměrnou distribuci, což umožní adekvátně zachytit závislosti v oblasti chvostů rozdělení pro provázanost extrémních ztrát, resp. pohybů aktiv. Dle provedení avizovaných testů získáváme výsledky uvedené v Tabulce 22. Obrázky 32 až 40 (příloha B) znázorňují závislosti, které vycházejí z testování obsaženého ve výše uvedené tabulce.

Jak už víme, tak lineární korelační koeficient byl dlouhou dobu využíván jako měřítko závislosti ve finančních oblastech. Přesto je vhodnější využívat modernějších prostředků, jako jsou výše citované kopula modely, které umožňují zachycovat

i asymetrické vazby na úrovni vícerozměrných rozdělení, tzn. pro zachycení situace, kdy spodní chvostová závislost může být vyšší než horní a naopak.

Tab. 22 Výsledky z odhadu kopula funkcí pro zvolené datové sety (četnosti typů kopulí při volbě)

Rodiny kopulí	I. interval	II. interval	III. interval
Gaussova	34,23%	35,43%	34,53%
Studentova t-kopula	34,46%	32,66%	33,48%
Claytonova	13,88%	14,26%	15,71%
Gumbelova	1,15%	1,32%	1,37%
Frankova	3,70%	3,72%	3,32%
Joeova	12,56%	12,51%	11,51%
BB1	0,00%	0,00%	0,00%
BB6	0,00%	0,00%	0,00%
BB7	0,00%	0,07%	0,05%
BB8	0,03%	0,02%	0,02%

Zachycení detailních párových vazeb jednotlivých kopulí je v případě 90 dimenzionálních dat velice problematické. Kvůli vysoké četnosti si musíme vystačit s obrazci, které jsou uvedené na Obrázcích 32 až 40 až pro první tři úrovně závislosti, viz příloha B.

Pracujeme tedy s 90 dimenzionálním datovým setem, denních výnosů akciových titulů pro analyzované společnosti. V základu bereme v potaz všechny dostupné kopula funkce obsažené v doplňku SW R, viz Tabulky 3 a 4, tedy je k dispozici Gaussova kopule, Studentova-t kopule, Claytonova kopule, Gumbelova kopule, Frankova kopule, Joeova kopule a následně i kopule BB1, BB6, BB7 a BB8⁷. Další varianty např. tvaru rotovaných kopulí (otočení závislosti o 90, 180 nebo 270 stupňů) netestujeme. Rodiny kopulí jsou finálně zvoleny na základě nejnižší hodnoty AIC (Akaike, 1974). Úvodní testování často bere do úvahy povahu vazby testovanou pomocí Vuongova a Clarkova testu – my vycházíme ze stejné úrovně závislosti, proto nepotřebujeme testování, zda je vazba ve tvaru C-, resp. D-Vine kopule. My volíme D-Vine kopuli, protože kvalitativně odpovídá účelu analýzy.

Po provedení odhadů je zjevné, že mnoho rodin kopula funkcí, které jsou k dispozici, není vhodných pro zpracování v tomto rozměru společností. Důvodem jsou technické obtíže se SW R, ze kterého nezískáváme uspokojivé výsledky po grafické stránce. I přes technické obtíže se zobrazením v práci využíváme i nesý-

⁷ BB1: Claytonova-Gumbelova kopule; BB6: Joeova-Gumbelova kopule; BB7: Joeova-Claytonova kopula, BB8: Joeova-Frankova kopule.

metrické kopule, které mají odlišný charakter než běžné normální rozdělení využívané v Mertonově modelu.

Na schématech v Obrázcích 32 až 40 v příloze B jsou zřetelné obrazce pro všechny roky vstupních dat, které následně využíváme pro sestavení odhadů upraveného Mertonova modelu. Společnosti, mezi kterými existuje určitá vazba, jsou spojené do určitého obrazce. Vazba existuje mezi společnostmi – pořadí společností, resp. určení značek V1 až V90 odpovídá značení společností v tabulkách. Cílem algoritmu je vytvořit strukturu seshora dolů, s postupným řazením podle úrovně intenzity závislostí (podle Kendallova tau). Z těchto vícerozměrných kopulí simulujeme uniformně rozdělené hodnoty z uniformního rozdělení na intervalu $[0,1]$, které dále využijeme pro určení pravděpodobností finanční situace (po transformaci inverzním cdf).

Tab. 23 Statistiky Kendallova tau pro data

Statistiky/Vstupní rok	2011	2012	2013
Minimum	-0,85	-0,84	-0,83
1. kvartil	-0,18	-0,19	-0,18
Medián	0	0,01	0,02
Průměr	0,03	0,03	0,03
3. kvartil	0,19	0,23	0,24
Maximum	0,72	0,78	0,78

Vícerozměrné t kopule byly již dříve často užívány pro modelování finančních výnosů, z toho důvodu není překvapivé, že pro naše účely se jedná o převažující vykazované typy kopulí. Důvodem je zajisté fakt, že slouží k zachycení chvostové závislosti v extrémních polohách rozdělení. To samé platí jako opodstatnění pro zařazení dalších rodin kopula funkcí, např. Gaussovy kopule, která byla častým základem kvantitativních modelů rizika. To odpovídá očekávané asymetrii finančních dat, jak uváděli Longin a Solnik (2001), Ang a Chen (2002) a další autoři, tj. že nižší chvostová závislost může být vyšší než ta horní a naopak.

Následně generujeme simulovaná data, která odpovídají charakteru typových kopula dat (hodnoty mezi 0 a 1, vč. těchto krajních hodnot).

Poté jsou tyto hodnoty postoupeny do simulace na základě strukturálních modelů. Algoritmus následně seřadil společnosti na první úrovni – tedy nejsilnější závislosti mezi společnostmi. Společnosti, ve kterých není viditelná závislost, nemají mezi sebou tak silné vazby, a proto nejsou zachyceny. Samotné vyčíslení parametrů je obtížné, vazeb zde existuje velké množství. Metodicky je výsledek ilustrován na Obrázku 2, kde je zobrazeno rozložení závislostí u párové kopule a lokalizace intenzity závislosti.

5.3.2 Odhad rizika pomocí Mertonova a Mertonova D-Vine kopula modelu

V této podkapitole představujeme výsledky odhadů rizika defaultů pomocí strukturálních modelů rizika na základně vstupních dat – uvedených pro všechny společnosti v Tabulkách 43 až 45 v příloze C. Zároveň uvedeme vazbu kreditního rizika na značky rizikovosti nebo nerizikovosti stanovené přes účetní proměnné. Tím pádem zobrazíme a srovnáme výsledky mezi účetními a strukturálními modely rizika. Spolu s tím poskytneme odhady volatility u společností, které jsou výrazným vstupním parametrem pro odhad strukturálních modelů rizika.


V Tabulce 24 vidíme, že pravděpodobnosti defaultu jsou vyšší u modelu založeném na D-Vine kopula modelu. To platí primárně pro hodnotu mediánu a 1. kvartil, kromě roku 2013. Model tedy kvantifikuje vyšší riziko než je tomu u Mertonova modelu, u kterého bylo při verifikaci na tržních datech prokázáno podhodnocení.

Tab. 24 Základní charakteristiky pravděpodobnosti defaultu

Statistika	Mertonův model			Mertonův D-Vine kopula model		
	2014	2013	2012	2014	2013	2012
Minimum	0,0%	0,0%	0,0%	0,0%	0,0%	0,0%
1. kvartil	0,0%	0,0%	0,0%	1,0%	3,0%	3,0%
Medián	0,0%	1,0%	1,0%	2,0%	4,0%	4,0%
3. kvartil	1,0%	8,0%	10,0%	2,0%	6,0%	5,0%
Maximum	100,0%	98,0%	100,0%	100,0%	93,0%	96,0%


Základní nebo také prahové modelu hodnoty jsou tedy vyšší pro všechny společnosti, což lépe reflektuje skutečnost, že společnosti obsahují určité riziko defaultu bez ohledu na jejich aktuální tržní výkonnost. Kdybychom vycházeli ze stejného vnímání modelů jako u Altmanova a Ohlsonova modelu, tak by hodnoty vyšší než 50 % vedly k závěru, že společnost je zbankrotovaná nebo že jí bankrot akutně hrozí v nejbližších letech. Jelikož žádná společnost nebankrotovala, tak se musíme dle námi zvolené metodiky spokojit s pouhým ohrožením rizikem. Na dendrogramech (Obr. 17 až 22) a v Tabulkách 25, 26 a 27 vidíme, že společnosti se shlukují tak jako v předchozích případech podle svého profilu. Můžeme tedy předpokládat, že hodnoty, které generuje námi odvozený D-Vine kopula strukturální model, popisují reálnou finanční situaci společností.

Společnost The Conygar Investment Company vzhledem ke svému stupni volatility, viz předchozí kapitola, vykazuje vysokou míru rizikovosti, zejména při pohledu z Mertonovy základní metodologie.



Obr. 17 Dendrogram založený na pravděpodobnostech z Mertonova modelu (rok 2014)

Jak vidíme, tak pravděpodobnosti generované ostatními metodami jsou násobně vyšší, což pravděpodobně lépe odpovídá reálným účetním hodnotám, které jsou mnohdy nadprůměrné.



Obr. 18 Dendrogram založený na pravděpodobnostech z Mertonova D-Vine kopula modelu (rok 2014)

Ze srovnání v Tabulce 25 až 27 je viditelné, že nejvyšší jsou hodnoty dané Ohlsonovým modelem, které jsou násobně vyšší, než korespondující číselné údaje z D-


Vine kopula modelu – jde tedy zcela jistě o nalezení určitých prahových hodnot, které vzájemně korespondují se značkami rizika. Prvních 20 nejrizikovějších společností dle tohoto srovnání je uvedeno v Tabulce 25, další následují níže.

Tab. 25 Nejrizikovější společnosti (rok 2014)


Společnosti	Pst. O	Pst. A	Pst. M-K	Pst. M	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
Eutelsat Communications	7,00%	19,40%	100,00%	100,00%	R	N	N	R
Northgate	5,00%	8,30%	99,90%	100,00%	R	N	N	R
The Conygar Investment C.	2,10%	15,20%	13,40%	61,50%	N	N	N	N
Future	48,10%	88,80%	8,90%	42,50%	N	R	R	R
Avon Rubber	12,80%	0,00%	8,10%	15,50%	R	N	R	R
Grainger	3,30%	12,00%	6,90%	16,50%	R	N	N	R
Plexus Holdings	68,60%	0,00%	6,20%	1,00%	N	N	N	N
The Alumasc Group	33,50%	6,20%	6,20%	32,00%	R	N	R	R
Mastrad	66,20%	20,60%	5,60%	27,70%	R	R	R	R
Anite	4,40%	1,20%	5,40%	0,00%	N	N	N	N
Carpentryright	51,10%	3,50%	4,90%	4,50%	R	R	R	R
Goldplat	3,50%	7,20%	4,90%	19,70%	N	N	N	N
Societe Centrale	66,40%	31,60%	4,50%	9,00%	R	N	R	R
Digital Bros	19,60%	4,80%	4,20%	12,50%	R	N	N	R
Clas Ohlson	2,50%	0,00%	3,90%	0,50%	N	N	R	N
Consort Medical	0,90%	0,10%	3,80%	0,00%	N	N	N	N
CVS Group	40,20%	1,50%	3,80%	1,20%	R	N	R	R
Allergy Therapeutics	9,30%	80,70%	3,60%	0,20%	N	N	N	N
Dechra Pharmaceuticals	1,70%	0,40%	3,50%	0,30%	N	N	N	N
Bastide LE Confort Medical	21,80%	7,10%	2,90%	2,00%	R	N	R	R

Oproti metrikám odvozených z Altmanova a Ohlsonova modelu zde tedy existuje určitá provázanost, kterou lze vysvětlit faktem, že vstupní proměnné jsou stejné. Ukazatele rizikovosti, které hodnotí kvalitu klasifikace, jsou ve vztahu s tržními metrikami rizika nepřesné u společností nejrizikovějších. Vidíme, že společnosti, které zde vykazují nejvyšší pravděpodobnosti rizika, patří k firmám, které jsou

z hlediska účetních proměnných nerizikové. Větší provázanost je zde s odhadnutou volatilitou zachycenou modelem volatility.




Obr. 19 Dendrogram založený na pravděpodobnostech z Mertonova modelu (rok 2013)




Obr. 20 Dendrogram založený na pravděpodobnostech z Mertonova D-Vine kopula modelu (rok 2013)

Tab. 26 Nejrizikovější společnosti (rok 2013)

Společnosti	Pst. O	Pst. A	Pst. M-K	Pst. M	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
J D Wetherspoon	66,10%	9,80%	93,30%	97,60%	R	N	R	R
The Conygar Investment C.	2,00%	16,50%	13,60%	59,50%	N	N	N	N
Future	13,30%	36,10%	8,60%	43,90%	N	R	R	R
Enterprise Inns	19,00%	25,80%	9,00%	38,30%	R	N	R	R
Pure Wafer	4,00%	3,70%	14,50%	37,80%	N	N	N	N
Barratt Developments	0,50%	8,30%	9,30%	31,40%	N	N	R	N
PZ Cussons	2,30%	1,40%	3,60%	25,50%	N	N	R	N
Galliford Try	3,90%	6,90%	5,80%	21,90%	N	N	R	R
Photo - ME International	1,10%	3,90%	3,60%	21,00%	N	N	N	N
Imagination Technologies G.	1,50%	0,00%	7,70%	17,10%	N	N	N	N
Northgate	8,00%	8,80%	8,50%	17,10%	R	N	N	R
Mastrad	25,70%	16,70%	3,70%	15,60%	R	R	R	R
ThyssenKrupp	15,90%	23,10%	4,60%	15,10%	R	N	R	R
Grainger	4,70%	11,60%	5,90%	13,60%	R	N	N	R
Mcbride	27,50%	9,40%	6,10%	13,40%	R	R	R	R
Digital Bros	21,40%	6,70%	5,00%	12,90%	R	N	N	R
Ashtead Group	14,40%	9,90%	7,70%	11,90%	R	N	R	R
DS Smith	11,00%	16,60%	5,60%	11,70%	R	N	R	R
Fenner	5,30%	5,60%	6,30%	11,70%	R	N	N	R
Wolseley	2,20%	1,70%	7,30%	11,40%	N	N	R	R



Obr. 21 Dendrogram založený na pravděpodobnostech z Mertonova modelu (rok 2012)



Obr. 22 Dendrogram založený na pravděpodobnostech z Mertonova D-Vine kopula modelu (rok 2012)

Tab. 27 Nejrizikovější společnosti (rok 2012)

Společnosti	Pvst. O	Pvst. A	Pvst. M-K	Pvst. M	Zadluženost	Zisk	Běžná likvidita	Koef. samof.
J D Wetherspoon	73,30%	11,20%	95,80%	97,30%	R	N	R	R
The Conygar Investment Company	2,80%	32,30%	13,10%	59,70%	N	N	N	N
Future	24,30%	40,10%	10,50%	32,90%	N	R	R	R
Pure Wafer	20,20%	80,40%	10,20%	63,10%	N	N	N	N
Enterprise Inns	17,70%	27,90%	10,00%	29,40%	R	N	R	R
PZ Cussons	16,40%	1,40%	9,70%	0,40%	N	N	R	N
Barratt Developments	0,50%	10,30%	9,30%	33,20%	N	N	R	N
Photo – ME International	6,10%	4,70%	8,90%	0,50%	N	N	N	N
Imagination Technologies G.	0,20%	0,00%	8,20%	3,80%	N	N	N	N
Northgate	13,30%	6,70%	8,20%	28,00%	R	N	N	R
Pan African Resources	0,30%	0,40%	7,90%	3,80%	N	N	R	N
Ashtead Group	16,60%	11,50%	7,50%	14,00%	R	N	R	R
Avon Rubber	13,10%	0,00%	7,40%	9,70%	R	N	R	R
Galliford Try	3,90%	7,20%	6,80%	20,30%	N	N	R	R
Wolseley	2,10%	2,80%	6,50%	10,10%	N	N	R	R
Fenner	5,60%	5,70%	6,40%	9,00%	R	N	N	R
Grainger	9,50%	16,60%	6,40%	13,60%	R	N	N	R
Redrow	0,70%	4,90%	6,40%	12,90%	N	N	R	N
Mastrad	17,60%	6,80%	6,30%	3,80%	R	R	R	R
DS Smith	3,00%	12,60%	6,30%	12,10%	R	N	R	R

5.3.3 Shrnutí průběžných výsledků

Tabulky 28 až 32 zobrazují statistiky pro vybrané ukazatele rizika, ze kterých je jasně patrné, že nerizikové společnosti podle přiřazení rizika mají také nižší pravděpodobnosti defaultu, než ty rizikové. Tak jak je patrné z předchozího textu, hodnoty pro Altmanův i Ohlsonův model jsou vyšší, než pro strukturální modely.

Tab. 28 Praviděpodobnosti finančních obtíží účetních modelů v letech 2012 až 2014

Statistika	Ohlsonův model				Altmanův model			
	2014	2013	2012	2011	2014	2013	2012	2011
Minimum	0,00%	0,20%	0,10%	0,00%	0,00%	0,00%	0,00%	0,00%
1. kvartil	2,10%	2,20%	2,00%	2,30%	1,20%	1,50%	2,20%	1,80%
Medián	5,60%	5,10%	5,40%	5,40%	4,50%	5,10%	5,60%	5,50%
3. kvartil	22,30%	14,20%	16,50%	14,90%	11,40%	11,20%	11,50%	11,10%
Maximum	100,00%	66,10%	73,30%	99,90%	100,00%	100,00%	99,90%	100,00%

Tab. 29 Praviděpodobnosti defaultu strukturálních modelů v letech 2012 až 2014

Statistika	Mertonův model			Mertonův D-Vine kopula model		
	2014	2013	2012	2014	2013	2012
Minimum	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
1.kvartil	0,00%	0,00%	0,00%	1,00%	3,00%	3,00%
Median	0,00%	1,00%	1,00%	2,00%	4,00%	4,00%
3. kvartil	1,00%	8,00%	10,00%	2,00%	6,00%	5,00%
Maximum	100,00%	98,00%	100,00%	100,00%	93,00%	96,00%

Pro data z roku 2014 platí, že medián Altmanova modelu leží v tzv. šedé zóně, tedy tam kde společnosti nejsou jasně vyhraněné. To platí jak pro rizikový, tak i nerizikový segment. Průměrná hodnota datového setu je výrazně vyšší.

Tab. 30 Základní statistiky rizikových ukazatelů s dělením na rizikové a nerizikové společnosti (v roce 2014)

Rizikovost	Ukazatel	Volatilita	Altmanův m.	Ohlsonův m.	Pst. O	Pst. A	Pst. M-K	Pst. M
R	Minimum	20,20%	-24,795	-7,176	0,10%	0,00%	0,70%	0,00%
	1. kvartil	21,50%	1,668	-2,624	6,80%	4,50%	1,40%	0,00%
	Medián	24,10%	2,365	-1,687	15,70%	8,60%	1,60%	0,10%
	3. kvartil	27,20%	3,065	-0,572	36,10%	15,90%	3,10%	2,00%
	Maximum	62,10%	62,672	1,108	75,20%	100,00%	100,00%	100,00%
	Průměr	28,20%	5,206	-1,738	23,60%	15,00%	8,80%	9,60%
N	Minimum	18,60%	-2,066	-113,237	0,00%	0,00%	0,10%	0,00%
	1. kvartil	21,90%	2,886	-4,674	0,90%	1,00%	1,40%	0,00%
	Medián	24,10%	3,59	-3,577	2,70%	2,70%	1,70%	0,00%
	3. kvartil	26,30%	4,569	-2,837	5,50%	5,30%	2,10%	0,20%
	Maximum	328,70%	14,213	31,544	100,00%	88,80%	13,40%	61,50%
	Průměr	32,20%	4,156	-4,949	10,90%	7,80%	2,40%	2,80%

V roce 2013 je ve srovnání s dalšími roky hodnota Z-skóre nižší, než v roce následujícím. To se promítá i do výše pravděpodobnosti úpadku.

Tab. 31 Základní statistiky rizikových ukazatelů s dělením na rizikové a nerizikové společnosti (v roce 2013)

Rizikovost	Ukazatel	Volatilita	Altmanův m.	Ohlsonův m.	Pst. O	Pst. A	Pst. M-K	Pst. M
R	Minimum	21,20%	-17,48	-4,26	1,40%	0,00%	0,10%	0,00%
	1. kvartil	28,40%	1,61	-2,64	6,70%	4,30%	2,70%	0,10%
	Medián	35,40%	2,30	-1,83	13,90%	9,10%	3,30%	2,40%
	3. kvartil	43,90%	3,11	-0,95	28,00%	16,60%	5,50%	11,70%
	Maximum	261,60%	72,92	0,67	66,10%	100,00%	93,30%	97,60%
	Průměr	42,90%	4,84	-1,79	19,70%	13,10%	6,20%	7,90%
N	Minimum	9,70%	-1,78	-6,19	0,20%	0,00%	0,30%	0,00%
	1. kvartil	26,40%	2,57	-4,36	1,30%	1,00%	2,50%	0,00%
	Medián	35,30%	3,29	-3,64	2,50%	3,60%	3,70%	0,50%
	3. kvartil	44,30%	4,56	-2,95	5,00%	7,10%	5,70%	6,90%
	Maximum	267,60%	13,59	-0,98	27,30%	85,60%	17,10%	59,50%
	Průměr	41,10%	4,14	-3,60	4,50%	6,80%	4,70%	6,60%

Tabulka 32, která popisuje výsledky pro rok 2012, ukazuje, že podkladová data pro rizikové společnosti dosahovala vyšších hodnot, tedy společnosti měly vyšší odvozené hladiny rizika. Stále ale obecně platí, že u pravděpodobností, které jsou nižší než 50 %, neohrožuje společnosti bankrot nebo finanční obtíže a opačně.

Tab. 32 Základní statistiky rizikových ukazatelů s dělením na rizikové a nerizikové společnosti (v roce 2012)

Rizikovost	Ukazatel	Volatilita	Altmanův m.	Ohlsonův m.	Pst. O	Pst. A	Pst. M-K	Pst. M
R	Minimum	20,60%	-7,25	-4,66	1,30%	0,00%	0,70%	0,00%
	1. kvartil	27,10%	1,59	-2,95	5,00%	4,60%	2,70%	0,10%
	Medián	33,20%	2,50	-1,86	13,50%	7,60%	3,60%	2,90%
	3. kvartil	42,30%	3,05	-1,03	26,30%	16,90%	5,30%	12,20%
	Maximum	239,00%	83,41	1,01	73,30%	99,90%	95,80%	100,00%
	Průměr	40,30%	5,08	-1,97	18,50%	12,80%	6,40%	10,60%
N	Minimum	9,60%	-1,41	-7,27	0,10%	0,00%	0,10%	0,00%
	1. kvartil	26,80%	2,38	-4,62	1,00%	1,70%	2,50%	0,10%
	Medián	33,00%	3,49	-3,66	2,50%	3,00%	3,80%	0,60%
	3. kvartil	43,20%	4,05	-2,29	9,30%	8,50%	5,10%	6,30%
	Maximum	283,10%	30,24	-0,98	27,30%	80,40%	13,10%	92,50%
	Průměr	40,30%	4,44	-3,58	5,80%	9,00%	4,30%	9,30%

Z dosavadních výsledků a výpočtů vyplývá, že Mertonův model není ideální pro zachycení rizika defaultu společností, ani pro analýzu současného stavu společností. Také je vhodné připomenout dříve realizované výzkumy, kde Mertonův model zachytil úspěšně riziko defaultu u společností s opravdu vysokým stupněm ohrožení finančními obtížemi. Lze pozorovat, že ve srovnání s ostatními modely poskytuje takřka nulové hodnoty pravděpodobností defaultu, což zdaleka neodpovídá skutečnosti. Z toho by se dalo odvodit, že buď takto zjednodušená podoba modelu, popř. potenciální tržní neefektivnost, neumožňuje systémově zachytit finanční skutečnosti, které ohraničují život společností. Z tohoto důvodu je s vysokou pravděpodobností vhodnější se zaměřit na ostatní modely zmíněné v této práci.

5.4 Klasifikace společností a vyhodnocení predikční síly modelů

V této části si představíme finální výsledky klasifikace pomocí rozhodovacích stromů a metody SVM a u obou zobrazíme výsledky v tabulce se sumarizací celkových chyb. Základní kroky, které jsme provedli, jsou:


- Rozdělení dat na podmnožiny: učící, validační a testovací část v poměru 30/30/40.
- Předzpracování dat pro odstranění vzájemně korelovaných proměnných (korelace v absolutní hodnotě vyšší než 0,8).
- Výběr a extrakce atributů je provedena automaticky ze strany klasifikačního algoritmu.
- Trénink, validace a predikce na datech se značkami, které vyjadřují rizikovitost z roku 2014.
- Hodnocení přesnosti klasifikace pomocí ukazatele celkové přesnosti klasifikace a chyb 1. a 2. typu.

Vzhledem k možnostem metody klasifikačních stromů, mezi kterými je i zobrazení klasifikačních pravidel, nejprve ukážeme výsledky z tohoto pohledu. Výhodou metody je i fakt, že zvolí pouze proměnné, které umožňují snadno popsat vztah mezi společnostmi, tedy zde existuje filtrace významných proměnných. Obrázky 23 až 28 zobrazují klasifikační stromy na základě zvolených atributů pro roky 2012 až 2014. Značka R zde značí pro konkrétní roky rizikové společnosti a značka N označuje společnosti nerizikové. Podíly procent ve spodní části grafu dávají součet 100 %. Procentní podíly uvedené výše ukazují přiřazení společností do podmnožiny uvnitř stromu nebo větve. Při pohledu shora dolů můžeme vidět postupnou bifurkaci, která postupně rozkládá data na základě zjištěných kritérií do dílčích elementů. Do klasifikace vstupují vždy data, která jsou uvedena v popisu schématu, ale klasifikační značky tvořily značky evidované za rok 2014. Vždy používáme dva

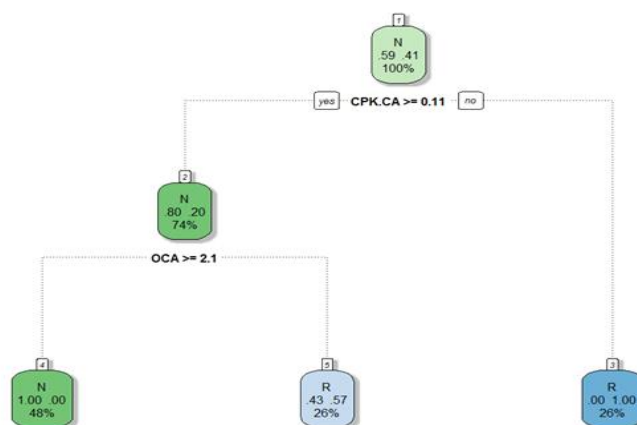
soubory dat – jeden s účetními proměnnými a druhý s „tržními“ proměnnými, ke kterým řadíme metriky ze strukturálních modelů rizika, včetně pravděpodobností finanční tísně účetních modelů. Cílovými klasifikačními značkami jsou zadluženost a běžná likvidita pro rok 2014.

Pro rok 2012 platí, že rozhodovací stromy obsahují prostou strukturu. Rizikové společnosti ze strany zadlužení měly dva roky před tímto hodnocením pravděpodobnost bankrotu podle Altmanova modelu vyšší, než 6 %. Jak ale vidíme, tak přesnost takového soudu je poměrně nízká. Existovalo 14 % společností, které byly klasifikované jako nerizikové, ačkoliv se projevily o dva roky jako rizikové. Celkově 31 % společností s vyšší pravděpodobností, než 6% se nakonec projevilo jako nerizikových.

Zadluženost (tržní model)



Zadluženost (účetní model)




Obr. 23 Schéma klasifikačního stromu (data z roku 2012)

Pomocí účetních dat se dostáváme ke složitějšímu modelu než v případě těch tržních. Model bere do úvahy, že společnosti, které jsou rizikové, mají vyšší hodnotu


než 0,11 v poměru čistého pracovního kapitálu a oběžných aktiv. Společnosti, kterých se to týkalo beze zbytku, byly správně klasifikovány jako rizikové. U společností s vyšší hodnotou, než je uvedená, se rozhodovací strom dále rozvětvil podle stavu operativních krátkodobých aktiv, která slouží jako podpora operací podniku. Jedná se o zásoby, hotovost a krátkodobé pohledávky. Jestliže společnost disponovala vyšší, částkou, než 2,1 tis EUR, tak se řadila mezi nerizikové. I přes toto restriktivní nastavení se ukazuje, že společnosti s nižší hodnotou mohly být nerizikové (viz u bodu č. 5 světle modré barvy na Obrázku 23).

Při hodnocení budoucí běžné likvidity již zpočátku vidíme, že struktura modelu je prostá. Pouze jedna proměnná stanovuje, zda jsou společnosti rizikové nebo nerizikové. V případě tržních dat využíváme proměnou pravděpodobnost z Ohlsonova modelu. Pokud byla vyšší než 15 %, tak v roce 2014 byly společnosti rizikové. Avšak i zde v důsledku vysokého odstupeu do cílového roku figuruje vysoká míra misklasifikace. 30 % společností rizikových bylo označeno jako nerizikové a celých 14 nerizikových naopak jako nelikvidní, popř. ohrožené nelikviditou.

Likvidita (tržní model)




Likvidita (účetní model)



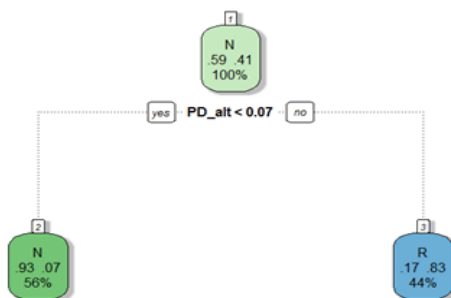
Obr. 24 Schéma klasifikačního stromu (data z roku 2012)

Tak jako pro rok 2012, tak i pro roky další hodnotíme grafické výstupy z klasifikace. V roce 2013 společnosti, které byly zadlužené více, než na úrovni 50 % měly ukazatel Altmanova modelu nižší nebo roven 2,6, viz Obrázek 25. Což se rovná tzv. šedé zóně, kde společnosti ještě nejsou v akutním ohrožení bankrotu, ale přesto je jejich budoucí stav nejasný. Přesnost této klasifikace je poměrně vysoká, resp. vyšší, než u případů za rok 2012. Pro tržní ukazatele také využíváme výstup z Altmanova modelu, ale v podobě pravděpodobnosti. Vidíme tedy, že přesnost klasifikace je naprosto stejná, avšak můžeme si přiřadit číselnou hodnotu pravděpodobnosti 7 % ke konkrétní výši Z-skóre.

Zadluženost (účetní model)



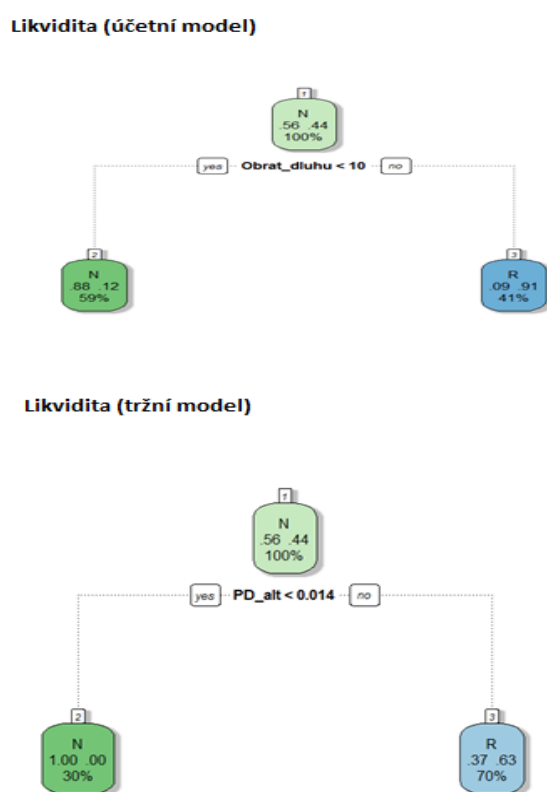
Zadluženost (tržní model)



Obr. 25 Schéma klasifikačního stromu (data z roku 2013)

Pro hodnocení rizika likvidity využíváme také vždy pouze jednu proměnnou. Společnosti, které měly obrat dluhů kratší, než 10 dní jsou převážně klasifikované jako nerizikové a opačně. Přesnost klasifikace je přitom poměrně vysoká. Tento ukazatel můžeme také nazývat průměrnou dobou odkladu plateb nebo dobou provozní-

ho úvěru.⁸ Tímto ukazatelem můžeme zjistit platební morálku podniku vůči dodavatelům, neboli jak dlouho firma odkládá platby faktur od dodavatelských subjektů. Můžeme ho také charakterizovat definicí, kolik dní podnik čerpá dodavatelský úvěr. Je vhodné, aby hodnota tohoto ukazatele byla vyšší než hodnota ukazatele Doba obratu pohledávek (doba splatnosti pohledávek). Podnik totiž může bezúročně využívat dodavatelských úvěrů. Možným způsobem výpočtu Doby obratu závazků je nejdříve vypočtení ukazatele Počet obrátek závazků, ze kterého se následně vypočítá Doba obratu závazků.



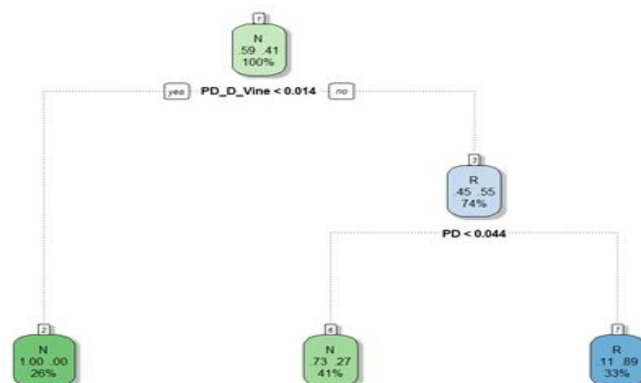
Obr. 26 Schéma klasifikačního stromu (data z roku 2013)

Stejně jako u rizika plynoucího ze zadlužení i v tomto případě využíváme pravděpodobnosti z Altmanova modelu ke klasifikaci společností. Místo hranice 7 % jako výše uvedené, nyní používáme více restriktivní úroveň – 1,4 %. Společnosti, které měly nižší tuto pravděpodobnost nižší než je tato hranice, byly bezpečně nerizikové. Společnosti rizikové byly také ohrazeny správně, avšak 37 % společností s vyšší pravděpodobností bylo označeno chybně. Vidíme, že takto nízko položená


⁸ Anglický překlad je payables turnover ratio.

hodnota pravděpodobnosti je neúměrně nízká. Posledním rokem, se kterým pracujeme, je rok 2014. Data vstupující do klasifikace odpovídají jak i svým obdobím, tak i klasifikačním značkám. Teoreticky bychom měli získat nejpřesnější výsledky, jak je patrné z předchozích studií nás i dalších autorů. U obou hodnocení likvidity i zadluženosti využíváme kombinace pravděpodobnostních ukazatelů, pro účetní hodnoty pouze jednoho. Jestliže hodnota pravděpodobnosti z Mertonova D-Vine kopula modelu byla nižší, než 1,4 % můžeme říct, že společnost je neriziková ze strany zadluženosti. Avšak u 45 společností to neplatilo. Znovu tedy narážíme na to, že příliš restriktivní hranice není vhodná. Doplnkovým ukazatelem je zde pravděpodobnost podle Ohlsonova modelu, odkud společnosti s pravděpodobností vyšší, než 4,4 % jsou také zařazeny jako rizikové. I přes to existují společnosti, které se nakonec projeví jako rizikové/nerizikové (až 27 % nerizikových a 11 rizikových). Jak jsme již upozornili dříve, tak existuje vazba mezi zadlužeností a koeficientem samofinancování. Jestliže byl tento ukazatel vyšší, než 48 %, byly společnosti správně klasifikovány jako nerizikové. V opačném případě kromě 21 % nesprávně stanovených společností sledujeme společnosti rizikové.

Zadluženost (tržní model)

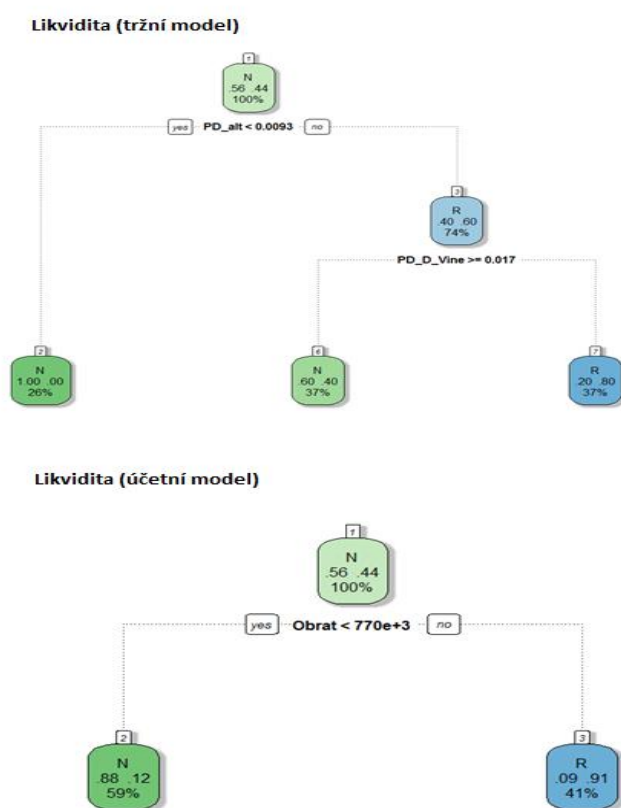


Zadluženost (účetní model)



Obr. 27 Schéma klasifikačního stromu (data z roku 2014)

V případě hodnocení likvidity využíváme v tržním modelu zase dvě proměnné. Nejprve pravděpodobnost podle Altmanova modelu a následně znovu pravděpodobnost z upraveného Mertonova modelu. Základní hranice je nižší, než 1 procento u A. modelu, což je zhruba na hranici 1. kvartilu tohoto ukazatele pro nerizikové společnosti. Takto restriktivní hodnota má znovu důsledek ve vysoké míře misklasifikace, protože až 40 % rizikově označených společností bylo nesprávně klasifikováno. Doprovodným kritériem je zde avizovaný ukazatel Mertonova D-Vine kupa modelu ve výši vyšší nebo nižší než 1,7 %, což je hodnota na hladině mediánu ze všech společností.



Obr. 28 Schéma klasifikačního stromu (data z roku 2014)

Pro klasifikaci likvidity znovu využíváme metriku obrat, která je nyní vyšší, než 770 milionů u rizikových společností. Přehledové číselné hodnoty klasifikace jsou obsaženy v Tabulkách 33 a 34. Po tom, co jsme realizovali předchozí kroky, byly zjištěny empirické přesnosti klasifikace. Celková přesnost modelu se zvyšuje s blízkostí do stanovení rizika v roce 2014, jak také vyplývalo z předchozích publikací. Rozdíl mezi přesností modelu SVM a rozhodovacích stromů je při hodnocení celkové přesnosti i dalších charakteristik nízký.

Tab. 33 Přesnost klasifikátorů pro běžnou likviditu

Klasifikátor/Období	Celková přesnost (%)			Chyba I. typu (%)			Chyba II. typu (%)		
	2012	2013	2014	2012	2013	2014	2012	2013	2014
Rozhodovací stromy – účetní	61,10	58,30	61,10	47,60	50,00	60,00	26,60	33,30	12,50
Rozhodovací stromy – tržní	63,90	58,30	69,40	46,10	50,00	7,60	10,00	39,20	21,00
SVM ANOVA RBF – účetní	63,90	69,40	58,30	47,60	35,70	50,00	26,70	27,20	33,30
SVM ANOVA RBF – tržní	61,10	58,30	58,30	46,10	50,00	50,00	10,00	20,00	20,00

Při klasifikaci podle zadlužení jsou přesnosti klasifikace vyšší, než v případě běžné likvidity, uvedené výše. Je však nutné upozornit, že výsledky klasifikace jsou velmi závislé na nastavení modelů. Jak vyplývá z četných zdrojů, viz např. Klepáč a Hampel (2016a).

Tab. 34 Přesnost klasifikátorů pro zadluženost

Klasifikátor/Období	Celková přesnost (%)			Chyba I. typu (%)			Chyba II. typu (%)		
	2012	2013	2014	2012	2013	2014	2012	2013	2014
Rozhodovací stromy – účetní	52,70	55,50	69,40	61,50	54,50	35,70	39,10	28,50	27,30
Rozhodovací stromy – tržní	58,30	55,50	77,70	52,60	54,50	31,30	29,40	28,50	15,00
SVM ANOVA RBF – účetní	58,30	72,20	59,40	52,20	37,50	50,00	23,10	20,00	23,10
SVM ANOVA RBF – tržní	52,80	75,00	69,40	56,50	36,70	43,50	30,80	11,70	7,70

6 Diskuze

Dizertační práce řeší problematiku hodnocení kreditního rizika podniku v obecné podobě a ze strany dvou ústředních směrů – účetních/bankrotních modelů (Altmanova modelu pro společnosti s veřejně obchodovatelnými akciemi, Ohlsonova modelu) a modelů strukturálních v podobě Mertonova a odvozeného Mertonova D-Vine kopula modelu, který spojuje tržní riziko společností s rizikem kreditním. V rámci práce zobecňujeme uplatnění těchto modelů i na případy mimo defaultní nebo bankrotní scénáře firem – využíváme klasifikačních značek dle stavu finančních poměrových ukazatelů. Tím se práce blíží testování predikční kvality klasifikátorů jako v Klepáč a Hampel (2016c) na datech platební neschopnosti společností, tedy stavu odlišného od běžněji voleného bankrotu/aktivity společnosti.

Indikátorem defaultu, jako nadřazeného pojmu pro různé finanční situace změny dle teorie strukturálních modelů rizika, je v těchto směrech pokles hodnot aktiva pod defaultní bariéru. To znamená, že aktiva nepokryjí splatnou velikost závazků. Model potom indikuje pravděpodobnost transformované hodnoty, které mohou předznamenat blížící se kreditní událost. Veřejně obchodovatelné akcie zohledňují nejaktuálnější informace související s firemními fundamenty a také prostřednictvím nich generované tržní hodnoty aktiv budou tyto informace obsahovat. Dovozená tržní cena aktiv tedy zahrnuje budoucí šance firmy a rovněž i relevantní informace o odvětví a ekonomice, ve které firma působí. Volatilita tržní ceny aktiv potom zohledňuje obchodní riziko firmy a riziko příslušného odvětví. Pro testování predikční přesnosti modelů využíváme relativně nových přístupů pro klasifikaci – rozhodovacích stromů a metody podpůrných vektorů. Hlavními přínosy práce jsou zejména následující zjištění:

- Práce ozřejmuje, jaká je v českém a evropském prostředí závislost mezi tržním rizikem veřejně obchodovatelném trhu a výstupů modelů kreditního rizika spolu s dříve uvedenými bankrotními modely.
- Práce poskytuje přehled postupů pro diagnostiku finanční situace společností obchodovaných na finančním trhu, pro specifický vývoj akciových dat té které společnosti při vědomí provázanosti s dalšími společnostmi na finančním trhu.
- V práci využíváme zobecněnou metodiku, která nevychází z natolik pevného nastavení klasifikačních značek – stavy odvozené z úrovní podnikových ukazatelů – likvidity a zadluženosti (běžně se posouzení omezuje jen na bankrotní nebo aktivní společnost). Díky tomu můžeme využívat metodiku i pro společ-

nost, které nezbankrotovaly. Jako finální rok analýzy využíváme data z roku 2014.

V práci dáváme do souvislosti tržní okolnosti, účetní proměnné a kreditní ukazatele, které vychází z původní teorie i z našeho rozšíření. V rámci analýzy se projeví jako důležité proměnné zejména výstupy Altmanova a Ohlsonova modelu, jak v podobě Z-skóre, tak i v přepočtu na pravděpodobnosti finančních potíží. Dále pracujeme s řadou účetních ukazatelů i ukazatelů rentability. Z námi navržených postupů prokázal hodnotu Mertonův D-Vine kopula přístup. Ačkoliv kriticky musíme říct, že klasifikační hranice je pro pravděpodobnosti nastavena velice striktně – rizikové společnosti jsou ohraničené již nad pár procentních bodů pravděpodobnosti k bankrotu. Což však neodpovídá celkové finanční situaci společností v budoucnosti.

Z řady dostupných metod, které v práci využíváme, volíme zejména metodu SVM a rozhodovací stromy, které si získaly popularitu při četných výzkumných studiích kvůli svým výhodným vlastnostem (využití datových vzorků z nenormálních rozdělání, filtrace vstupních proměnných pro zjednodušení vztahů, rozličné nastavení vedoucí k optimalizaci odhadů). Mezi autory se řadili zejména Min a Lee (2005), Ding, Song a Zen (2008), Niknya, Darabi a Vakili (2013) apod., kteří na základě srovnání mnohých metod získali výsledky s rozličnou úrovní přesnosti. Autoři těchto studií rovněž využívali větší datové vzorky než v našem případě s cílovou značkou bankrot nebo aktivní společnost. Z tohoto důvodu je obtížné objektivně srovnávat výsledky mezi naší a jejich prací. Lze však obecně tvrdit, že metody SVM nebo klasifikačních stromů jsou slibným přístupem pro vytvoření výstražných finančních modelů, srovnatelné s dalšími metodami umělé inteligence, jak jsme prokázali v navazujícím výzkumu.

Testování strukturálních modelů je obtížnější než v případě bankrotních modelů, kde jsou data ohraničená jasnými klasifikačními značkami: bankrot nebo přežití společnosti, viz dřívější práce Jones, Mason a Rosenfeld (1984) nebo Leland (2004), Eom, Helwege a Huang (2004). Autoři obvykle využívali jako cílové hodnoty regrese nebo klasifikace ceny dluhopisů, změny ratingů nebo kreditních spreadů – tedy kontraktů z kreditního trhu. Naše odlišné pojetí práce s volnějším pojetím klasifikačních značek je tedy poměrně ojedinělé.

Důležitým se při konfrontaci našich výsledků a práce jiných autorů jeví, že podle Campbell a Taksler (2003) volatilita akcií výrazně ovlivňuje rozpětí dluhopisů – tedy úroveň rizikové přírážky. Podobná studie v podmínkách ČR v posledních letech chyběla (ačkoliv se zabýváme pouze 4 společnostmi obchodovanými v ČR), částečné zpracování na případu dvou firem pro širší spektrum strukturálních modelů lze nalézt např. u Míška (2006) nebo Peška (2007), který odvozoval vysvětlo-

vací schopnosti Mertonova modelu oproti datům z ratingového hodnocení většího počtu českých společností.

Obecným rysem těchto studií je, že většinou vypovídají o nižších hodnotách pravděpodobnosti defaultu, než odpovídá historickým pro období do pěti let, z toho důvodu jsme použili ohraničení strukturálních modelů čtyřmi roky. Ze srovnání kreditních/strukturálních modelů vyplývá, že Mertonův model opravdu podhodnocuje rizikovost společností pro nastavených čtyřletý horizont. Ačkoliv zde jistě existuje určitá vnitřní fundamentální pravděpodobnost, z modelování vyplývá, že je nulová.

Ze získaných výsledků plyne, že Mertonův model není ideální pro zachycení rizika defaultu společností, ani pro analýzu současného stavu společností. Také je vhodné připomenout dříve realizované výzkumy, kde Mertonův model zachytil úspěšně riziko defaultu u společností s opravdu vysokým stupněm ohrožení finančními obtížemi. Lze také pozorovat, že ve srovnání s ostatními modely poskytuje takřka nulové hodnoty pravděpodobnosti defaultu, což zdaleka neodpovídá realitě. Z toho by se dalo odvodit, že buď takto zjednodušená podoba modelu, popř. potenciální tržní neefektivnost, neumožňuje systémově zachytit finanční skutečnosti, které ohraničují život společností. Z tohoto důvodu je s vysokou pravděpodobností vhodnější se zaměřit na ostatní modely zmíněné v této práci.

Námi navržený zobecněný Mertonův D-Vine kopula model nabízí vyšší hodnoty pravděpodobnosti defaultu, než v základní Mertonově podobě. To platí zejména pro základní hodnoty a nižší kvartily, než je medián. Upravený Mertonův model ohodnotil společnosti v tomto segmentu výše, pro společnosti domněle nejrizikovějších jsou pravděpodobnosti naopak nižší. Výsledky Mertonova modelu se více blíží hodnotám z Altmanova a Ohlsonova modelu, kde jsou pravděpodobnosti rizika ještě celkově vyšší, než u ostatních modelů.

Náročnost takto zobecněného kopula modelu je při výpočtech násobně vyšší – zejména pro datový set zahrnující více než 10 společností. Z našich předchozích výzkumů, viz např. Klepáč a Hampel (2015) lze navíc hovořit o diskutabilním uplatnění vícerozměrných Vine kopulí pro zachycení rizikových ukazatelů – zejména z důvodu obtížně zachytitelné proměnlivé závislosti v čase. Možné a v praxi uchopitelné úpravy Mertonova modelu by mohly pracovat s vícerozměrnou Studentovou-t kopulí, zejména z důvodu nižší pracnosti při odhadu a zpracování výsledků.

Při testování kvality výsledků vycházíme ze zjednodušené metodiky, která se uplatnila např. v Klepáč a Hampel (2016b), z výpočetních a časových důvodů bylo nemožné obsáhnout všechny dostupné kombinace vstupů do modelů – možné úpravy mohou vést ke kvalitnějším výsledkům experimentální metodiky. To samé se týká nastavení hranic pro klasifikaci, kdy vycházíme z teoretických předpokladů

i subjektivního odhadu. Samotná přesnost klasifikace by byla z našeho pohledu vyšší u bankrotních scénářů – při dostupnosti dostatečně obsáhlého datového souboru.

Výběr proměnných byl stanoven na základě různých technik – využíváme přístupy založené na metodě hlavních komponent, odstranění korelovaných proměnných i volně na extrakci algoritmů podle metody SVM i rozhodovacích stromů. Poslední jmenovaný přístup má však pro naše výsledky nevýhodu v tom, že je selekce proměnných příliš radikální v případě, že zůstala pouze jedna samostatná proměnná. Celková přesnost klasifikace, ačkoliv nevyužíváme přímo data zbankrotovaných společností, není natolik odlišná jako výsledky z výsledků našich předchozích bankrotních studií. To se týká zejména hodnot s vyšším zpožděním vůči roku klasifikace. Odlišných a vyšších hodnot, tedy misklasifikace, dosahujeme při analýze jednotlivých typů chyb, která je zejména při hodnocení rizika společností klíčová, viz Aziz a Dar (2006).

Při bližším zaměření se na chybu 1. a 2. typu, což je klíčové při analýze bankrotu a finanční situace společností, jsou hodnoty misklasifikace opravdu značné, zejména s větším odstupem před r. 2014. Předpokládáme, že podle našich předchozích výsledků z predikce bankrotu, je možné tyto výsledky vylepšit volbou dalších technik pro volbu atributů. Výběr proměnných a jeho další zpřesnění je potenciálně užitečné při klasifikaci, avšak vyžaduje velice přesné a komplexní analýzy dat.

7 Závěr

Hlavním cílem dizertační práce bylo na základě provedených kvantitativních analýz a modelování sestavit a otestovat výpočetní algoritmy pro klasifikaci krizových scénářů veřejně obchodovatelných společností při využití kopula funkcí a strukturálních modelů rizika. Pro naplnění hlavního cíle práce jsme museli vypracovat dílčí cíle:

- Systematizovat nejvýznamnější proudy z teorie predikce finanční tísně podniku a kreditního rizika: blíže analyzovat účetní a strukturální modely a metody podpurných vektorů a rozhodovacích stromů. Využít pravděpodobnosti defaultu nebo bankrotu odvozené z modelování při klasifikaci bankrotu a krize a použít je za účelem klasifikace zobecněných modelů rizika – testování klasifikačních značek po výše dle stavu ukazatele likvidity a zadluženosti.
- Rozšířit teorii o model transformující tržní riziko do podoby rizika kreditního za využití vícerozměrné D-Vine kopula funkce a Mertonova strukturálního modelu kreditního rizika.
- Otestovat přístupy pro klasifikaci krize jako stavu s delším průběhem v podmínkách evropských zemí pomocí metody podpurných vektorů (SVM) a rozhodovacích klasifikačních stromů. Srovnat jejich predikční schopnosti pomocí metod data miningu na různě specifikovaných datových souborech a v různém předstihu před scénářem finančního ohrožení (dle stavu společnosti v roce 2014).

V dizertační práci byly využity strukturální modely rizika jako přístupy k zachycení budoucího potenciálu k finančním obtížím společností z pohledu výraznějších změn ve finanční struktuře společnosti pro střednědobý horizont. Výsledky analýz doplňujeme o vlastní přístup založený na zachycení závislosti mezi akciemi společností na finančním trhu. Tyto přístupy ověřujeme na změně dalších podnikových ukazatelů. Protože chceme výsledky alespoň částečně ověřit a zobecnit, musíme vycházet z dat více společností působících na méně vyspělém trhu a na trzích vyspělejších, které představují společnosti z EU. V ČR nedošlo ve sledovaném období k bankrotu likvidní veřejně obchodované společnosti, proto musíme vycházet z jemnějšího chápání rizikových modelů, a také z jiných ukazatelů, jako je např. změna ratingu či výraznější zhoršení finanční situace (krizové scénáře dle stavu podnikových ukazatelů).

V práci byly představeny bankrotní a strukturální modely rizika spolu s výsledky výzkumů, které se zabývaly jejich rozšířením. Tato část ozřejmuje variabilitu oblasti modelování kreditního rizika zejména skrze hlubší pohled na provázání mezi kapitálovou strukturou společností a kreditními ukazateli společnosti,

kdy vycházíme z teorie hybridních modelů rizika. Jejím cílem je také poskytnout základní matematický přehled o vztazích užívaných v popsáných modelech. Moderní oborová literatura využívá ukazatelů z bankrotní analýzy pro klasifikaci bankrotu pomocí pokročilých data miningových přístupů, kam můžeme řadit metodu podpůrných vektorů, na jejíž empirické testování jsme se také zaměřili.

V části materiál a metodika popisujeme dílčí kroky a metody, které vedly k řešení praktické části práce. Zaměřujeme se i na výzkumy a využitá řešení dalších autorů. Zde se zaměřujeme i na detailní popis řešení modelových vztahů pro získání vstupních parametrů. Tato kapitola mimo jiné obsahuje i základní přehled metod, které využíváme při klasifikaci společností, které se řadí do data miningu nebo vícerozměrné statistiky: metoda SVM a rozhodovacích stromů, odhady kopula funkcí.

Finální částí a hlavním přínosem práce je sestavení a aplikace Mertonova D-Vine kopula modelu k odhadu rizika finančních obtíží společností na datech společností během let 2011 až 2013. V této části se snažíme určit, jaká je vazba tržního rizika na pravděpodobnost defaultu společností. Kromě toho počítáme kreditní ukazatele a na jejich základě klasifikujeme společnosti dle rizika (zadluženost, likvidita).

Při vědomí veškerých datových omezení a výpočetních možností se cíle podařilo naplnit, upravený Mertonův model poskytuje vyšší hodnoty defaultu než základní modely. Jak se ukázalo, tak účetní modely nadhodnocují riziko – společnosti, které měly být přímo ohrožené bankrotem se s odstupem takto neprojeví – zda reakci managementu mezi lety 2011 až 2013 nebo vnějšími vlivy není zjevné. Podařilo se ale prokázat, že existuje vztah mezi výsledky odhadovaného stavu společností, který indikují Ohlsonův i Altmanův model. Vysoké úrovně kvality společností v Altmanově modelu predeterminují i vysokou kvalitu společností přes Ohlsonův model a naopak. I přesto tyto společnosti obsahují určitou míru pravděpodobnosti rizika ohrožení bankrotem – což lépe odpovídá rizikovitosti společností, než v případě Mertonova modelu, který riziko v krátkém horizontu podhodnocuje.

Společnosti, které upřednostňuje Altmanův model mají nadprůměrné hodnoty rentability ROA i ROE, podprůměrný obrat dluhu, výši čistého pracovního kapitálu, nižší – podprůměrný poměr mezi fixním a celkovými aktivy i solidní likviditu.

U Ohlsonova modelu jsou společnosti více likvidní, než v případě Altmanova modelu, s tím je spojen i vyšší koeficient samofinancování, což společnosti činí ještě stabilnější – z toho srovnání účetních modelů tedy vychází jako výhodnější oproti Altmanovu modelu.

Srovnáním dvou strukturálních modelů rizika, které svými proměnnými vycházejí ze stejného základu, můžeme říct, že výsledky jsou podobnější než v případě účetních modelů, a to i přesto, že je jeden z modelů upravený o vícerozměrné

kopule. Právě odlišnost vstupních proměnných zapříčiňuje obtížnou srovnatelnost výsledů těchto dvou podkategorií modelů. Strukturální modely jsou velmi závislé na vstupní volatilitě aktiv, tedy společností, jejichž akcie jsou vysoce volatilní mají vyšší rizikovost. Při srovnání kvality modelů vycházíme z predikce, kterou provádíme skrze rozhodovací stromy a metodu SVM, které se osvědčily v dřívějších studiích nás i jiných autorů.

Při analýze jsme využívali dvě dělení dat – na datový set s účetními proměnnými a na ukazatel volatility akcií společností a pravděpodobnostní metriky ze strukturálních i účetních modelů rizika. Celková přesnost modelů na základě testování se pohybovala mezi 50 až 70 %, přičemž pro hodnocení bankrotu nebo finančních obtíží je nutné nahlížet i na míry misklasifikace, které mohou dramaticky změnit kvalitativní hodnocení modelů. Ze srovnání plyne, že čím blíže se přibližujeme k roku 2014, tím nižší chybovost dostáváme. Vyšší celkovou přesnost mají modely plynoucí z klasifikačních značek na základě zadluženosti, avšak při hodnocení dílčí skupin chybovosti se jeví jako vhodnější pro klasifikaci běžná likvidita, zejména ve vazbě na rozhodovací stromy – s tržními a pravděpodobnostními atributy.

Pro data z roku 2012 při odhadu stavu v roce 2014 platilo, že pro ohrožení zadlužeností se řídíme ze všech proměnných hodnotou pravděpodobnosti bankrotu dle Altmanova modelu nižší nebo vyšší, než 6 %. Při využití účetních dat volíme dvě proměnné: poměr čistého pracovního kapitálu a oběžných aktiv ve výši 0,11 a doprovodně i stavem operativních krátkodobých aktiv vyšším než 2,1 tisíce euro.

Při hodnocení rizika likvidity si vypomáháme zejména pravděpodobností z Ohlsonova modelu, na úrovni 15 % a výši obratu ve výši 972 tisíc euro. Přesnost těchto modelů však není příliš vysoká, což je dáno právě velkým odstupem od hodnotícího roku 2014. V mezidobí mohlo dojít k výraznějším změnám ze strany vedení apod.

Při hodnocení následujícího roku vycházíme z toho, že u zadluženosti hrají hlavní roli Altmanův model, jak v účetní podobě dle hodnoty skóre, tak i při přepočtu na pravděpodobnost. Klíčové hodnoty jsou ve výši 2,6 %, resp. 7 % v případě pravděpodobnosti.

Do klasifikace likviditního scénáře vstupuje obrat dluhu vyšší než 10 a u pravděpodobnosti znovu Altmanův model, nyní na úrovni 1,4 %. Existuje zde tedy určité rozpětí mezi 1,4 % až 6 % a výše, do kterého spadá velké množství takto rizikových společností. I v tomto případě se ukazuje, že dolní hranice intervalu 1,4 % je příliš striktní, některé společnosti byly dostatečně likvidní. Pro finální rok, který poskytoval nejpřesnější hodnoty klasifikace platí, že míra zadluženosti indikuje pravděpodobnost defaultu z Mertonova-D-Vine kopula modelu, vyšší než 1,4 % ve spojení s ukazatelem z Ohlsonova modelu vyšším, než 4,4 %. Klasifikace čistě podle

nového modelu není příliš úspěšná, díky této proměnné bylo přesně stanoveno pouze 59 % společností. Účetní model využívá kritérium podle míry samofinování: pokud je hodnota vlastního kapitálu vůči pasivům vyšší než 48 %, tak jsou společnosti ze strany zadlužení nerizikové.

Likvidita je hodnocena ze strany Altmanova modelu v takřka nulové výši, ve vazbě na ukazatel pravděpodobnosti našeho modelu na úrovni 1,7 %. Do hodnocení likvidity čistě z účetních dat znovu vstupuje hodnota obratu, tentokrát ve výši 770 tisíc euro.

Vzhledem k faktu, že empirické studie neposkytují dostatečnou oporu ve výsledcích pro rozšířené vícerozměrné strukturální modely, obzvláště pro české společnosti, musíme se spolehnout na výsledky získané z vlastních měření. Z tohoto důvodu je prakticky nemožné zcela objektivně říct, do jaké míry jsou výsledky uspokojivé nebo naopak.

Bez ohledu na tyto skutečnosti platí, že předkládaná práce rozpracovává pro budoucnost prakticky stále aktuální problematiku, která s dalším rozvojem výpočetních prostředků umožní zachytit zejména dynamickou a nelineární závislost odvozených kreditních ukazatelů.

8 Literatura

Monografie:

1. ALTMAN, E. I., HOTCHKISS, E. *Corporate financial distress and bankruptcy: predict and avoid bankruptcy, analyze and invest in distressed debt*, 2006. Hoboken, NJ: Wiley. ISBN 0-471-69189-5.
2. ARLT, J., ARLTOVÁ, M. *Ekonomické časové řady*. 1. vyd. Praha: Profesional Publishing, 2009, 290 s. ISBN 98-80-247-1319-9.
3. COOMBS, W. *Ongoing crisis communication: planning, managing, and responding*. Fourth edition. xiii 239 pages. ISBN 978-145-2261-362.
4. DUFFIE, D., SINGLETON, K. J. *Credit Risk* (Princeton University Press). 2003, s. 416, ISBN 9781400829170.
5. CHERUBINI, U. *Dynamic copula methods in finance*. 2nd ed. Hoboken, NJ: Wiley, 2011, x, 274 s.
6. CHERUBINI, U., LUCIANO, E., VECCHIATO, W. *Copula methods in finance*. Hoboken, NJ: John Wiley & Sons, c2004, xvi, 293 s. Wiley finance series.
7. FINK, S. *Crisis management: planning for the inevitable*. Lincoln: iUniverse, c2002, xii, 245 s. ISBN 0-595-09079-6.
8. INSTITUTION, British Standards. *PAS 200:2011 crisis management: guidance and good practice*. London: British Standards Institution, 2011. ISBN 0580764788.
9. JAMES, G. R. *An introduction to statistical learning: with applications in R*. New York: Springer, c2013, xiv, 426 s. Springer texts in statistics, ISBN 9781461471370.
10. KNÁPKOVÁ, A., PAVELKOVÁ, D. *Finanční analýza: komplexní průvodce s příklady*. 1. vyd. Praha: Grada, 2010, 205 s. ISBN 978-80-247-3349-4.
11. NELSEN, R. B. *An introduction to copulas*. New York: Springer, c2006, 269 s. ISBN 03-872-8659-4.
12. RANK, J. *Copulas: from theory to application in finance*. London: Risk Books, 2007. ISBN 978-190-4339-458.
13. SCHOUTENS, W., CARIBONI, J. *Lévy processes in credit risk*. Chichester, U.K.: John Wiley & Sons, c2009, ix, 185 s. ISBN 0470743069.
14. STROUHAL, J. *Využití účetních dat ve finanční praxi aneb základní metody finanční analýzy*. 2008. Mzdová praxe.
15. SYNEK, M. *Manažerská ekonomika*. 4., aktualiz. a rozš. vyd. Praha: Grada, 2007, 452 s. ISBN 978-80-247-1992-4.

16. SEEGER, M., TIMOTHY W., SELNOW, L., ULMER, R. *Communication and organizational crisis*. Westport, Conn.: Praeger, c2003, x, 297 p. ISBN 1567205348.
17. RAIS, R. *Specifika krizového managementu*. Ostrava: KEY Publishing s.r.o., 2007. 92 s. ISBN 978-80-87071-11-3.
18. VAPNIK, V. M. *The Nature of Statistical Learning Theory*. 1995. New York: Springer.
19. ZUZÁK, R., KÖNIGOVÁ, M. *Krizové řízení podniku*. 2. aktualiz. vyd. [s.l.] : Grada Publishing, a.s., 2009. 253 s. ISBN 978-80-247-3156-8.

Ostatní publikace:

20. AAS, K., CZADO, C., FRIGESSI, A. a kol. *Pair-copula constructions of multiple dependence*. Insurance: Mathematics & Economics, 2009, roč. 44, vyd. 2, s. 182-198. DOI: 10.1016/j.insmatheco.2007.02.001.
21. AGARWAL, V., TAFFLER, R. Does Financial Distress Risk Drive the Momentum Anomaly?. *Financial Management*. 2008, roč. 37, vyd. 3, s. 461-484 [cit. 2015-03-18]. DOI: 10.1111/j.1755-053x.2008.00021.x.
22. ALTMAN, E. I. *Financial ratios, diskriminant. Financial ratios, diskriminant analysis and the prediction of corporate bankruptcy*. *The Journal of Finance*. 1968, roč. 23, vyd. 4, s. 589-609 [cit. 2015-03-18] DOI: 10.1111/j.1540-6261.1968.tb00843.x.
23. ALTMAN, E. I., HALDEMAN, R. G., NARAYANAN, P. *ZETA analysis: A new model to identify bankruptcy risk of corporations*. *Journal of Banking*. 1977, roč. 1, vyd. 1, s. 29-54 [cit. 2015-03-18]. DOI: 10.1016/0378-4266(77)90017-6.
24. ANDRADE, G., KAPLAN, S. N. *How costly is financial (not economic) distress? Evidence from highly leveraged transactions that became distressed*, 1998. *Journal of Finance*, roč. 53, s. 1443-1493 [cit. 2015-03-18]. DOI: 10.3386/w6145
25. AZIZ, M. A., DAR, H. A. *Predicting corporate bankruptcy: where we stand?*. *Corporate Governance: The international journal of business in society*. 2006, roč. 6, vyd. 1, s. 18-33 [cit. 2015-03-18]. DOI: 10.1108/14720700610649436.
26. BALCAEN, S., OOGHE, H. *35 years of studies on business failure: an overview of the classical statistical methodologies and their related problems*, Vlerick Leuven Gent Management School Working Paper Series, 2004, 56 s
27. BARBAN, A., PERSIO, L. D. *Multivariate Option Pricing with Pair-Copulas*. *Journal of Probability*. 2014, s. 1-11 [cit. 2015-03-18]. DOI: 10.1155/2014/839204.

28. BAXTER, M. *Lévy simple structural models*. International Journal of Theoretical and Applied Finance. 2007, roč. 10, vyd. 4, s. 593–606 [cit. 2015-03-18]. DOI: 10.1142/s021902490700438x.
29. BEAVER, W. H. *Financial Ratios as Predictors of Failure*, Journal of Accounting Research, roč. 4, 1966, s. 71-102.
30. BHARATH, S. T., SHUMWAY, T. *Forecasting Default with the KMV-Merton Model*. SSRN Electronic Journal. [cit. 2015-03-18]. DOI: 10.2139/ssrn.637342.
31. BOYACIOGLU, M. A., KARA, Y., BAYKAN, O. K. *Predicting bank financial failures using neural networks, support vector machines and multivariate statistical methods: A comparative analysis in the sample of savings deposit insurance fund (SDIF) transferred banks in Turkey*. Expert Systems with Applications. 2008, roč. 36, vyd. 2, s. 3355–3366 [cit. 2015-03-18]. DOI: 10.1016/j.eswa.2008.01.003.
32. BRECHMANN, E. C., SCHEPSMEIER, U. *Modeling dependence with C- and D-vine copulas: The R-package CDVine*. 2013. R vignette of the R-package CDVine. Dostupné z: <https://www.jstatsoft.org/article/view/v052i03/v52i03.pdf>
33. CAMPBELL, J. Y., TAKSLER, G. B. *Equity Volatility and Corporate Bond Yields*. The Journal of Finance. 2003, roč. 58, vyd. 6, s. 2321–2350 [cit. 2015-03-18]. DOI: 10.1046/j.1540-6261.2003.00607.x.
34. COLLIN-DUFRESNE, P., GOLDSTEIN, R. S., MARTIN, J. S. *The Determinants of Credit Spread Changes*. The Journal of Finance. 2001, roč. 56, vyd. 6, s. 2177–2207 [cit. 2015-03-18]. DOI: 10.1111/0022-1082.00402.
35. COX, J. C., BLACK, F. *Valuing corporate securities: Some effects of bond indenture provisions*. The Journal of Finance, 1976, roč. 31, vyd. 2, s. 351–367 [cit. 2015-03-18]. DOI: 10.1111/j.1540-6261.1976.tb01891.x.
36. CROSBIE, P., BOHN, J. *Modeling Default Risk, Moody's KMV*, 2003. Dostupné z: http://www.macs.hw.ac.uk/~mcneil/F79CR/Crosbie_Bohn.pdf
37. DEAKIN, E. B. *A Discriminant Analysis of Predictors of Business Failure*, Journal of Accounting Research, roč. 10, vyd. 1, 1972, 167–179 [cit. 2015-03-18]. DOI: 10.2307/2490225.
38. DELIANEDIS, G., GESKE, R. *Credit Risk and Risk Neutral Default Probabilities: Information about Rating Migrations and Defaults*. 1998. UCLA, The Anderson School, working paper.
39. DELIANEDIS, G., GESKE R. *The Components of Corporate Credit Spreads: Default, Recovery, Taxes, Jumps, Liquidity, and Market Factors*. SSRN Electronic Journal [online]. 2001. [cit. 2016-08-06]. DOI: 10.2139/ssrn.306479.

40. DEMIROVIC, A., THOMAS, D.C. *The Relevance of Accounting Data in the Measurement of Credit Risk*. The European Journal of Finance . 2007, roč. 13, vyd. 3, s. 253–268 [cit. 2015-03-18]. DOI: 10.1080/13518470601025177.
41. DIßMANN, J., BRECHMANN, E. C., CZADO, C., KUROWICKA, D. *Selecting and estimating regular vine copulae and application to financial returns*. Computational Statistics & Data Analysis . 2013, roč. 59, s. 52–69 [cit. 2015-03-18]. DOI: 10.1016/j.csda.2012.08.010.
42. DING, Y., SONG X., ZEN X. *Forecasting financial condition of Chinese listed companies based on support vector machine*. Expert Systems with Applications . 2008, roč. 34, vyd. 4, s. 3081–3089 [cit. 2015-03-26]. DOI: 10.1016/j.eswa.2007.06.037.
43. DUAN, J-CH. *THE GARCH OPTION PRICING MODEL*. Mathematical Finance . 1995, roč. 5, vyd. 1, s. 13–32 [cit. 2015-03-18]. DOI: 10.1111/j.1467-9965.1995.tb00099.x.
44. DUFEE, G. R. *The relation between treasury yields and corporate bond yield spreads*, 1998, Journal of Finance, roč. 53, vyd. 6, 2225–2241 [cit. 2015-03-25]. DOI: 10.1111/0022-1082.00089.
45. DUFFIE, D., SAITA L., WANG, K. *Multi-period corporate default prediction with stochastic covariates*. Journal of Financial Economics . 2007, roč. 83, vydání 3, s. 635–665 [cit. 2015-03-25]. DOI: 10.1016/j.jfineco.2005.10.011.
46. ELTON, E. J., GRUBER M. J., AGRAWAL, D., MANN, CH. *Explaining the rate spread on corporate bonds*, Journal of Finance, 2001, roč. 56, s. 247–277 [cit. 2015-03-25]. DOI: 10.1111/0022-1082.00324.
47. EOM, Y. H., HELWEGE, HUANG, J. *Structural Models of Corporate Bond Pricing: An Empirical Analysis*, 2004. Review of Financial Studies 17, s. 499–544 [cit. 2015-03-18]. DOI: 10.1093/rfs/hhg053.
48. FAWCETT, T. *ROC Graphs: Notes and Practical Considerations for Researchers*. Technická zpráva HP Laboratories. Kluwer Academic Publishers, 2004. Dostupné z: <http://www.hpl.hp.com/techreports/2004/HPL-2004-4.pdf>
49. GEPP, A., KUMAR, K., BHATTACHARYA, S. *Business failure prediction using decision trees*. Journal of Forecasting, 2010, roč. 29, vyd. 6, 536–555 [cit. 2015-03-18]. DOI: 10.1002/for.1153.
50. GEMMILL, G. *Testing Merton's model for credit spreads on zero-coupon bonds*. Working Paper. Coventry: Warwick Business School, Financial Econometrics Research Centre. 2002. Dostupné z http://www2.warwick.ac.uk/fac/soc/wbs/subjects/finance/research/wpa_perseries/2002/02-118.pdf

51. GESKE, Robert. *The Valuation of Corporate Liabilities as Compound Options*. The Journal of Financial and Quantitative Analysis. 1977, roč. 12, vyd. 4, s. 541–556 [cit. 2015-03-18]. DOI: 10.2307/2330330.
52. HILLEGEIST, S. A., KEATING, E. K., CRAM, D. P., LUNDSTEDT, K. G. *Assessing the Probability of Bankruptcy*. Review of Accounting Studies . 2004, roč. 9, vyd. 1, s. 5–34 [cit. 2015-03-18]. DOI: 10.1023/b:rast.0000013627.90884.b7.
53. HUA, Z. a kol. *Predicting corporate financial distress based on integration of support vector machine and logistic regression*. Expert Systems with Applications, roč. 33, vyd. 2, 2007, s. 434–440 [cit. 2015-03-18]. DOI: 10.1016/j.eswa.2006.05.006.
54. HUANG, Z. a kol. *Credit rating analysis with support vector machines and neural networks: a market comparative study*. Decision Support Systems. 2004, vyd. 37, roč. 4, 543–558 [cit. 2016-08-07]. DOI: 10.1016/S0167-9236(03)00086-1.
55. HUANG, J. Z., HUANG, M. *How Much of Corporate-Treasury Yield Spread Is Due to Credit Risk?: A New Calibration Approach*. SSRN Electronic Journal . [cit. 2015-03-25]. DOI: 10.2139/ssrn.307360.
56. HUANG, K., YU, H., CHEN, C., *The application of decision trees to forecast financial distress companies*. Proceedings of International Conference on Intelligent Technologies and Applied Statistics, Taipei, Taiwan, 2005.
57. HULL, J., PREDESCU, M., WHITE, A. *The valuation of correlation-dependent credit derivatives using a structural model*. Working Paper, 2005.
58. CHAN, K., CHEN, K. *Structural and Return Characteristics of Small and Large Firms*, 1991. Journal of Finance 46, s. 1467–1484 [cit. 2015-03-18].
59. JOE, H. *Families of m -variate distributions with given margins and $m(m + 1)/2$ bivariate dependence parameters*. In L. Rauchendorf and B. Schweizer and M. D. Taylor (Ed.), Distributions with mixed marginals and related topics. 1996.
60. JONES, E. P., MASON, S., ROSENFELD, E. *Contingent Claims Analysis of Corporate Capital Structures: An Empirical Investigation*. The Journal of Finance, 51. 1984, s. 987–1019 [cit. 2015-03-18].
61. KARELS, G. V., PRAKASH, A. J. *Multivariate Normality and Forecasting of Business Bankruptcy*. Journal of Business Finance & Accounting. 1987, roč. 14, vyd. 4, s. 573–593 [cit. 2015-03-18]. DOI: 10.1111/j.1468-5957.1987.tb00113.x.
62. KEALHOFER, S., KURBAT, M. *The default prediction power of the Merton approach, relative to debt ratings and accounting variables*. Moody's KMV, 2001. Dostupné z:

- <http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=6936BCA6636D5133B152D3A5E1BB14CC?doi=10.1.1.101.7279&rep=rep1&type=pdf>
63. KIM, SOO Y., UPNEJA, A. *Predicting restaurant financial distress using decision tree and AdaBoosted decision tree models*. Economic Modelling, 2014, 36: 354-362 [cit. 2016-07-12]. doi: 10.1016/j.econmod.2013.10.005.
 64. KLEPÁČ, V. *Assesing Probability of Default: Merton Model Approach*. InPEFnet 2014. 1. vyd. Brno: Mendel University Press, 2014, s. 76 [cit. 2015-03-18].
 65. KLEPÁČ, V., HAMPEL D. Assessing efficiency of D-Vine copula GARCH method in Value at Risk forecasting: Evidence from PSE listed companies. Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis, roč. 63, vyd. 1, 2015. DOI: 10.11118/actaun201563041287
 66. KLEPÁČ, V., HAMPEL D. Prediction of bankruptcy with SVM classifiers among retail business companies in EU. Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis, roč. 64, vyd. 2, 2016a. DOI: 10.11118/actaun201664020627.
 67. KLEPÁČ, V., HAMPEL D. Predicting bankruptcy of manufacturing companies in EU. E+M Ekonomie a Management, 2016b, v tisku.
 68. KLEPÁČ, V., HAMPEL D. Predicting financial distress of agriculture companies in EU. Zemědělská ekonomika, 2016c, v tisku.
 69. KLEPÁČ, V., KAMARÝTOVÁ, S. Using SVM Method for Classification of Retail Companies from the Point of Financial Risk. In *XXXII International Colloquium on the Management of Educational Process*. 33. vyd. Brno: University of Defence, 2015, s. 1-10.
 70. KORTEKAAS, M. P. A Vine Copula-GARCH Option Pricing model. Master's Thesis in Financial Econometrics, 2013, Faculty of Economics and Business, University of Amsterdam.
 71. LEE, Y. C. *Application of support vector machines to corporate credit rating prediction*. Expert Systems with Applications, č. 33, vyd. 1, 2007, s. 67-74 [cit. 2015-03-18]. DOI: 10.1016/j.eswa.2006.04.018.
 72. LELAND, H. *Predictions of Default Probabilities in Structural Models of Debt (Digest Summary)*. Journal of Investment Management, roč. 2, No. 25-20. 2004. DOI: 10.2469/dig.v35.n1.1611
 73. LI, H., SUN, J., WU, J. *Predicting busines failure using classification and regression tree: an empirical comparison with popular classical methods and top classification mining methods*. Expert Syst. Appl., roč. 37, vyd. 8, 2010, 5895-5904 [cit. 2015-03-18]. DOI: 10.1016/j.eswa.2010.02.016.
 74. LIN, F., MCLEAN, S. *A data mining approach to the prediction of corporate failure*. Knowl.-Based Syst. 14 (3-4), 2001, 189-195 [cit. 2015-03-18]. DOI: 10.1007/978-1-4471-0275-5_7.

75. LONGSTAFF, F., SCHWARTZ, E. A. *Simple Approach to Valuing Risky Fixed and Floating Rate Debt*. The Journal of Finance, 50 (1995), s. 789–819 [cit. 2015-03-18].
76. LUCIANO, E., SCHOUTENS, W. *A multivariate jump-driven financial asset model*. Quantitative Finance. 2006, roč. 6, vyd. 5, s. 385–402 [cit. 2015-03-18]. DOI: 10.1080/14697680600806275.
77. MERTON, R. C. *On the Pricing of Corporate Debt: The Risk Structure of Interest Rates*, Journal of Finance, 1974, American Finance Association, roč. 29, vyd. 2, s. 449–70 [cit. 2015-03-18].
78. MIN, A., CZADO, C. *Bayesian inference for multivariate copulas using paircopula constructions*. 2008. Preprint. Dostupné z: <https://mediatum.ub.tum.de/doc/1079212/1079212.pdf>
79. MIN, S. H., LEE, J., HAN, I. *Hybrid genetic algorithms and support vector machines for bankruptcy prediction*. Expert Systems with Applications, roč. 31, 2006, s. 652–660 [cit. 2016-08-07]. DOI: 10.1016/j.eswa.2005.09.070
80. MIN, J. H., LEE, Y. C. *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 [cit. 2016-08-07]. DOI: 10.1016/j.eswa.2004.12.008.
81. MÍŠEK, R. *Strukturální modely kreditního rizika*. 2006. VŠE. Dizertační práce.
82. NIKNYA, A., DARABI, VAKILI F. *Financial Distress Prediction of Tehran Stock Exchange Companies Using Support Vector Machines*. European Online Journal of Natural and Social Science, 2013, roč. 2.
83. OHLSON, J. A. *Financial ratios and the probabilistic prediction of bankruptcy*. Journal of Accounting Research. 1980, roč. 18, vyd. 1, s. 109–131 [cit. 2015-03-18].
84. OVERBECK, L., SCHMIDT, W. *Modeling Default Dependence with Threshold Models*. The Journal of Derivatives . 2005, roč. 12, vyd. 4, s. 10–19 [cit. 2015-03-18]. DOI: 10.3905/jod.2005.517182.
85. PATTON, A. J. *Modelling asymmetric Exchange rate dependence*. International Economic Review. 2006, roč. 47, vyd. 2, s. 527–556 [cit. 2015-03-18]. DOI: 10.1111/j.1468-2354.2006.00387.x.
86. PATTON, A. J., OH, D. H. *Modelling Dependence in High Dimensions with Factor Copulas*. Working Paper. Duke University. 2012.
87. PITERKOVÁ, A., BIELIKOVÁ, T., BÁNYIOVÁ, T. *The classification of agribusiness entities from the point of financial risk*. PEFnet 2013. Brno: Mendel University Press, 2013.

88. PEARSON, CH. M., SOMMER, S. A. *Infusing creativity into crisis management*. *Organizational Dynamics*. 2011, roč. 40, vyd. 1, s. 27–33 [cit. 2015-03-18]. DOI: 10.1016/j.orgdyn.2010.10.008.
89. PEŠKA, M. *The Applicability of Merton's Credit Risk Model in the Czech Republic*. IES UK. 2007. Diplomová práce.
90. PSILLAKI, M., TSOLAS I. E., MARGARITIS D. *Evaluation of credit risk based on firm performance*. *European Journal of Operational Research*. 2010, roč. 201, vyd. 3, s. 873–881 [cit. 2015-03-26]. DOI: 10.1016/j.ejor.2009.03.032.
91. SARIG, O., WARGA, A. *Some Empirical Estimates of the Risk Structure of Interest Rates*. *The Journal of Finance*. 1989, roč. 44, vyd. 5, s. 1351–1360 [cit. 2015-03-25]. DOI: 10.1111/j.1540-6261.1989.tb02657.x.
92. SHIN, K. S., LEE, T. S., KIM, H. J. *An application of support vector machines in bankruptcy prediction model*. *Expert Systems with Applications*, č. 28, 2005, s. 127–135 [cit. 2015-03-18]. DOI: 10.1016/j.eswa.2004.08.009.
93. SHUMWAY, T., 2001: *Forecasting Bankruptcy More Accurately: A Simple Hazard Model*. *Journal of Business*, roč. 74, vyd. 1, 101–24 [cit. 2015-03-18]. DOI: 10.1086/209665. ISSN 0021-9398.
94. SKLAR, A. *Fonctions de répartition à n dimensions et leurs marges*. *Publ. Inst. Statist.* 1959. Univ. Paris, 8: 229–231 [cit. 2015-03-18].
95. SOBENHART, J. R., STEIN, R. M., MIKITYANSKAYA, V., LI, L., *Moody's Public Firm Risk Model: A Hybrid Approach to Modeling Short-Term Default Risk*, 2000. Moody's Investors Service.
96. „Crisis“. websters-online-dictionary.org. ICON Group International, Inc.
97. ZAVGREN, CH. V. *Assesing the vulnerability to failure of American industrial firms: A logistic analysis*. *Journal of Business Finance & Accounting*. 1985, roč. 12, vyd. 1, s. 19–45 [cit. 2015-03-26]. DOI: 10.1111/j.1468-5957.1985.tb00077.x.
98. ZMIJEWSKI, M. *Methodological issues related to the estimation of financial distress prediction models*, *Journal of Accounting Research*, Spring, 1984, s. 59–86 [cit. 2015-03-18]. DOI: 10.2307/2490859

Přílohy

A Základní statistické charakteristiky a složení komponent

Tab. 35 Základní statistické charakteristiky zvolených ukazatelů pro rok 2014

Charakteristika	Minimum	1. kvartil	2. kvartil	3. kvartil	Maximum
Obrat (tis. EUR)	16 800,52	122 596,21	514 973,68	1 689 429,73	41 884 000,00
EBIT (tis. EUR)	-44 490,82	6 649,83	43 111,35	149 889,86	3 376 317,55
Fixní aktiva/Celková aktiva	0,03	0,41	0,53	0,71	0,97
Čistý pracovní kapitál (tis. EUR)	-136 492,47	4 571,19	35 214,60	198 603,58	6 639 134,95
Celková aktiva (EUR)	18 809,84	144 581,29	393 882,93	2 058 981,98	36 045 000,00
Čistý pracovní kapitál/ Celková aktiva	-0,09	0,07	0,17	0,28	0,78
Cash flow/Celková aktiva	0,00	0,03	0,07	0,11	0,44
EBIT/Celková aktiva	-0,50	0,06	0,09	0,13	0,36
Obrat/Celková aktiva	0,06	0,62	0,97	1,47	4,50
Doba obratu pohledávek (dny)	0,00	18,08	35,06	53,14	117,07
Doba obratu dluhů (dny)	0,30	1,65	4,37	31,97	109,11
Běžná likvidita	0,20	0,67	0,96	1,36	4,50
Zadluženost (%)	2,10	18,94	50,01	119,78	731,29
Obrat čistých aktiv	-34,60	1,05	3,18	11,70	230,65
Úrokové krytí	-1,88	4,13	7,31	19,85	242,74
Cash flow (tis. EUR)	-78 694,75	8 745,75	48 455,20	167 938,44	8 039 208,95
Pohotovostná likvidita	-0,06	0,96	1,61	2,36	26,70
Koeficient samofinancování (%)	-0,15	29,73	47,38	62,73	82,47
EBIT marže (%)	-92,73	5,65	12,15	18,85	84,96
ROE (%)	-108,59	8,55	15,92	26,55	199,24
ROA (%)	-51,45	3,70	6,99	12,34	35,95

Tab. 36 Základní statistické charakteristiky zvolených ukazatelů pro rok 2013

Charakteristika	Minimum	1. kvartil	2. kvartil	3. kvartil	Maximum
Obrat (tis. EUR)	12 441,39	122 977,06	462 809,80	1 479 533,19	38 925 000,00
EBIT (tis. EUR)	-709 000,00	5 987,99	39 011,36	125 121,60	4 028 539,65
Fixní aktiva/Celková aktiva	0,03	0,41	0,54	0,71	0,99
Čistý pracovní kapitál (tis. EUR)	-91 916,06	5 014,58	39 471,92	201 037,96	6 082 143,80
Celková aktiva (EUR)	14 968,18	137 079,35	432 577,57	1 606 608,03	35 297 000,00
Čistý pracovní kapitál/ Celková aktiva	-0,07	0,07	0,17	0,29	0,80
Cash flow/Celková aktiva	0,00	0,03	0,07	0,12	0,49
EBIT/Celková aktiva	-0,46	0,06	0,08	0,12	0,34

Obrat/Celková aktiva	0,06	0,59	0,99	1,38	4,54
Doba obratu pohledávek (dny)	0,00	20,31	35,17	52,64	111,86
Doba obratu dluhů (dny)	0,38	1,55	4,42	29,78	132,32
Běžná likvidita	0,19	0,64	1,00	1,40	3,82
Zadluženost (%)	-0,02	18,92	45,24	120,12	766,36
Obrat čistých aktiv	-86,90	1,08	2,82	8,41	218,50
Úrokové krytí	-0,90	4,22	6,66	18,00	143,63
Cash flow (tis. EUR)	-157 000,00	7 459,08	39 083,00	128 210,89	3 518 954,63
Pohotová likvidita	-4,94	0,96	1,52	2,34	27,94
Věřitelské riziko (%)	-2,79	29,73	45,61	61,62	85,32
EBIT marže (%)	-16,15	5,55	11,31	19,16	72,61
ROE (%)	-146,88	7,56	15,16	23,70	201,96
ROA (%)	-48,31	3,26	6,38	10,72	34,50

Tab. 37 Základní statistické charakteristiky zvolených ukazatelů pro rok 2012

Charakteristika	Minimum	1. kvartil	2. kvartil	3. kvartil	Maximum
Obrat (tis. EUR)	13 574,24	124 775,73	524 929,78	1 434 689,68	42 179 000,00
EBIT (tis. EUR)	-3 849 000,00	5 660,93	36 609,55	135 118,31	3 913 762,98
Fixní aktiva/Celková aktiva	0,04	0,40	0,54	0,74	0,99
Čistý pracovní kapitál (tis. EUR)	-109 441,91	6 946,60	35 988,13	166 399,82	6 195 906,25
Celková aktiva (EUR)	18 270,01	141 794,74	411 502,81	1 690 556,17	38 284 000,00
Čistý pracovní kapitál/ Celková aktiva	-0,08	0,07	0,16	0,28	0,81
Cash flow/Celková aktiva	0,00	0,03	0,06	0,13	0,53
EBIT/Celková aktiva	-0,17	0,05	0,09	0,13	0,33
Obrat/Celková aktiva	0,07	0,60	0,99	1,56	4,68
Doba obratu pohledávek (dny)	0,00	20,35	34,36	50,91	106,76
Doba obratu dluhů (dny)	0,37	1,55	3,32	34,59	133,13
Běžná likvidita	0,12	0,68	0,94	1,36	3,99
Zadluženost (%)	0,14	20,29	49,48	113,71	976,42
Obrat čistých aktiv	-6,60	1,18	2,67	11,20	304,46
Úrokové krytí	-4,19	3,97	6,90	16,08	154,34
Cash flow (tis. EUR)	-29 013,53	7 164,14	39 723,83	146 536,23	3 081 674,47
Pohotová likvidita	-11,56	0,97	1,51	2,16	29,78
Věřitelské riziko (%)	-6,74	29,57	46,83	61,12	84,20
EBIT marže (%)	-9,13	4,64	10,46	18,29	52,47
ROE (%)	-97,53	7,15	16,94	24,77	208,90
ROA (%)	-19,96	3,70	7,18	11,92	33,07

Tab. 38 Základní statistické charakteristiky zvolených ukazatelů pro rok 2011

Charakteristika	Minimum	1. kvartil	2. kvartil	3. kvartil	Maximum
Obrat (tis. EUR)	10 289,51	104 194,00	431 364,04	1 249 887,30	43 120 000,00
EBIT (tis. EUR)	-208 124,95	6 397,47	27 477,61	120 942,64	3 049 011,39
Fixní aktiva/Celková aktiva	0,04	0,45	0,55	0,74	0,98
Čistý pracovní kapitál (tis. EUR)	-83 561,74	5 255,24	30 896,45	174 249,66	7 536 000,00
Celková aktiva (EUR)	15 409,90	124 492,30	353 307,58	1 343 523,25	43 603 000,00
Čistý pracovní kapitál/Celková aktiva	-0,07	0,08	0,17	0,27	0,79
Cash flow/Celková aktiva	0,00	0,04	0,06	0,12	0,33
EBIT/Celková aktiva	-0,25	0,05	0,08	0,13	0,32
Obrat/Celková aktiva	0,07	0,58	0,99	1,38	4,17
Doba obratu pohledávek (dny)	0,00	21,06	36,74	53,77	107,39
Doba obratu dluhů (dny)	0,00	1,41	3,49	33,81	134,19
Běžná likvidita	0,13	0,63	0,93	1,37	4,35
Zadluženost (%)	0,41	21,65	51,63	127,41	941,00
Obrat čistých aktiv	-14,99	1,12	2,52	8,06	641,38
Úrokové krytí	-1,87	3,81	6,82	16,29	484,29
Cash flow (tis. EUR)	-110 000,00	6 445,02	27 097,75	115 023,15	2 787 997,54
Pohotová likvidita	-18,00	0,97	1,44	2,01	30,72
Věřitelské riziko (%)	-10,34	26,78	45,13	60,20	85,66
EBIT marže (%)	-23,07	5,82	10,54	16,93	71,20
ROE (%)	-108,14	6,82	15,95	26,00	355,11
ROA (%)	-25,72	3,39	6,39	11,73	32,59

Tab. 39 Složení dílčích komponent 2011

Ukazatel	Komponenty							
	1	2	3	4	5	6	7	8
Obrat (tis. EUR)	x	x	x	x	x	x	x	x
EBIT (tis. EUR)	-0,46	0,16	x	x	x	-0,16	x	x
Fixní aktiva/Celková aktiva	-0,12	x	0,60	x	x	x	x	x
Čistý pracovní kapitál (tis. EUR)	x	x	-0,20	x	-0,25	0,20	x	x
Celková aktiva (EUR)	-0,45	0,12	x	x	-0,12	-0,21	x	x
Čistý pracovní kapitál/Celková aktiva	x	x	-0,53	-0,14	-0,18	0,26	-0,12	-0,19

Cash flow/Celková aktiva	0,15	0,25	x	x	0,31	-0,43	0,15	0,38
EBIT/Celková aktiva	x	x	x	0,24	x	0,17	x	-0,27
Obrat/Celková aktiva	0,11	x	-0,17	0,50	x	-0,28	0,13	-0,21
Doba obratu pohledávek (dny)	-0,15	x	x	-0,12	0,35	0,12	x	-0,35
Doba obratu dluhů (dny)	-0,23	x	-0,26	x	0,18	0,30	-0,19	0,40
Běžná likvidita	0,17	0,25	x	-0,29	0,23	-0,34	x	-0,13
Zadluženost (%)	-0,15	-0,19	-0,20	0,18	0,11	x	x	-0,40
Obrat čistých aktiv	0,00	0,22	0,13	-0,14	-0,13	-0,30	0,00	-0,23
Úrokové krytí	0,11	0,14	x	-0,37	-0,37	x	-0,34	0,58
Cash flow (tis. EUR)	-0,40	0,16	x	x	x	x	0,53	x
Pohotová likvidita	x	0,24	x	0,47	0,46	0,18	0,12	x
Věřitelské riziko (%)	0,22	0,20	x	-0,33	0,33	x	0,43	x
EBIT marže (%)	x	0,30	0,31	x	x	0,39	x	x
ROE (%)	x	0,19	x	0,24	0,24	x	x	0,22
ROA (%)	x	0,48	x	x	x	0,13	x	-0,22

Tab. 40 Složení dílčích komponent 2012

Ukazatel	Komponenty									
	1	2	3	4	5	6	7	8	9	10
Obrat (tis. EUR)	0,34	x	0,17	0,26	-0,2	x	x	0,18	x	x
EBIT (tis. EUR)	0,1	-0,34	-0,2	-27	0,12	0,28	0,28	-0,32	x	-0,12
Fixní aktiva/Celková aktiva	x	-0,1	-0,53	0,27	0,21	x	x	0,16	x	x
Čistý pracovní kapitál (tis. EUR)	0,31	-0,24	0,15	x	x	x	x	-0,26	x	x
Celková aktiva (EUR)	0,37	-0,23	x	0,14	x	x	x	x	x	x
Čistý pracovní kapitál/ Celková aktiva	x	x	0,45	-0,38	0,11	-0,11	-0,11	-0,18	x	-0,11
Cash flow/Celková aktiva	-0,18	-0,15	0,18	0,21	-0,24	x	x	-0,31	0,11	x
EBIT/Celková aktiva	-0,22	-0,35	x	-0,14	-0,24	-0,14	-0,13	0,29	x	x
Obrat/Celková aktiva	x	0,22	x	-0,11	-0,52	0,32	0,31	x	0,13	0,11
Doba obratu pohledávek (dny)	0,16	x	x	-0,15	0,17	0,41	0,41	0,1	0,53	0,19
Doba obratu dluhů (dny)	0,21	x	0,18	-0,25	x	x	x	0,13	-0,38	0,65
Běžná likvidita	-0,21	-0,17	0,17	0,33	x	0,12	0,12	-0,2	0,18	x
Zadluženost (%)	0,16	x	-0,26	x	-0,26	-0,38	-0,39	-0,41	-0,12	-0,15
Obrat čistých aktiv	-0,2	-0,18	0,13	0,3	-0,1	x	x	-0,26	-0,11	0,38
Úrokové krytí	-0,13	x	-0,11	0,19	-0,14	0,56	0,56	x	-0,49	x
Cash flow (tis. EUR)	0,3	-34	x	x	x	0,2	0,2	-0,11	x	-0,11
Pohotová likvidita	x	-0,34	0,11	x	x	0,11	0,1	0,26	-0,41	-0,48
Věřitelské riziko (%)	-0,24	-0,18	0,27	0,11	0,28	x	x	x	x	x

EBIT marže (%)	-0,11	-0,14	-0,15	x	0,24	-0,18	-0,19	x	-0,14	x
ROE (%)	-0,11	-0,19	-0,25	-0,29	-0,35	-0,12	-0,12	-0,16	x	0,22
ROA (%)	-0,23	-0,35	x	-0,13	-0,25	x	x	0,28	0,11	x

Tab. 41 Složení dílčích komponent 2013


Ukazatel	Komponenty									
	1	2	3	4	5	6	7	8	9	10
Obrat (tis. EUR)	-0,35	x	x	x	0,31	-0,17	0,2	x	-0,22	x
EBIT (tis. EUR)	-0,35	-0,23	x	x	x	x	-0,35	x	0,1	0,14
Fixní aktiva/Celková aktiva	x	x	0,55	0,31	-0,1	x	x	x	x	x
Čistý pracovní kapitál (tis. EUR)	-0,37	-0,15	x	-0,15	x	-0,27	-0,12	x	x	x
Celková aktiva (EUR)	-0,42	x	x	x	0,18	-0,1	x	x	x	x
Čistý pracovní kapitál/Celková aktiva	x	x	-0,43	-0,37	-0,3	-0,24	x	-0,12	-0,12	x
Cash flow/Celková aktiva	0,14	-0,19	x	-0,15	0,6	x	x	0,33	0,33	0,18
EBIT/Celková aktiva	x	-0,46	-0,15	0,2	x	x	0,18	-0,18	-0,18	x
Obrat/Celková aktiva	x	0,16	-0,37	0,36	0,2	x	-0,29	-0,24	-0,24	0,12
Doba obratu pohledávek (dny)	-0,17	x	x	x	x	0,49	-0,28	-0,12	-0,12	-0,6
Doba obratu dluhů (dny)	-0,23	-0,28	x	x	-0,2	0,22	0,21	0,24	0,25	-0,3
Běžná likvidita	0,16	-0,15	0,18	-0,29	0,3	0,17	x	-0,43	-0,43	x
Zadluženost (%)	-0,25	0,15	x	0,15	0,2	x	0,52	-0,23	-0,23	x
Obrat čistých aktiv	0,15	-0,23	x	x	0,4	-0,25	x	-0,46	0,46	-0,4
Úrokové krytí	0,12	x	x	0,28	0,2	-0,17	-0,33	-0,23	-0,27	-0,3
Cash flow (tis. EUR)	-0,37	-0,21	x	x	x	x	-0,32	0,46	x	0,12
Pohotovostná likvidita	x	-0,13	x	-0,27	0,1	0,47	0,11	-0,27	-0,15	0,33
Věřitelské riziko (%)	0,21	-0,17	0,15	-0,35	-0,1	-0,35	-0,13	x	-0,21	x
EBIT marže (%)	x	-0,33	0,35	x	-0,2	x	0,19	-0,15	x	-0,2
ROE (%)	x	-0,32	-0,21	0,32	-0,1	0,23	x	-0,21	x	0,17
ROA (%)	x	-0,47	-0,18	0,18	x	x	0,15	x	-0,16	x

Tab. 42 Složení dílčích komponent 2014


Ukazatel	Komponenty									
	1	2	3	4	5	6	7	8	9	10
Obrat (tis. EUR)	-0,4	x	x	x	x	0,3	x	0,11	x	0,15
EBIT (tis. EUR)	-0,39	-0,16	-0,16	x	x	0,1	x	x	x	x
Fixní aktiva/Celková aktiva	x	0,1	-0,17	-0,61	0,11	x	x	x	x	x
Čistý pracovní kapitál (tis. EUR)	-0,35	-	-0,16	0,18	0,2	x	x	0,11	x	x

		0,16								
Celková aktiva (EUR)	-0,4	-0,12	-0,16	x	x	0,1	x	x	x	x
Čistý pracovní kapitál/ Celková aktiva	x	-0,15	y	0,54	0,23	-0,2	0,2	x	x	0,14
Cash flow/Celková aktiva	0,16	-0,16	-0,14	x	-0,44	0,4	x	0,18	0,21	x
EBIT/Celková aktiva	x	-0,47	0,21	x	x	x	x	-0,15	x	x
Obrat/Celková aktiva	x	0,15	0,47	x	x	0,4	x	-0,23	-0,27	x
Doba obratu pohledávek (dny)	-0,16	0,16	y	0,11	-0,19	-0,2	x	-0,79	0,21	0,26
Doba obratu dluhů (dny)	-0,24	-0,16	0,16	0,23	-0,13	-0,2	-0,19	0,14	0,6	x
Běžná likvidita	0,19	-0,22	-0,31	x	-0,34	0,1	x	x	-0,22	0,52
Zadluženost (%)	-0,21	-0,14	0,27	-0,21	-0,31	x	0,27	0,28	x	0,24
Obrat čistých aktiv	0,18	-0,12	x	x	x	0,4	0,21	-0,21	0,38	-0,53
Úrokové krytí	x	x	x	-0,11	0,33	0,4	-0,63	x	0,25	0,32
Cash flow (tis. EUR)	-0,36	-0,18	-0,17	x	x	0,1	x	-0,14	-0,23	-0,14
Pohotová likvidita	0,25	-0,36	-0,13	0,2	-0,4	-0,2	-0,58	x	-0,31	-0,31
Věřitelské riziko (%)	x	-0,31	-0,37	x	0,28	x	0,12	x	x	0,19
EBIT marže (%)	x	-0,48	x	-0,26	x	-0,4	x	x	0,11	x
ROE (%)	x	-0,33	0,39	-0,18	-0,16	x	x	x	-0,13	x
ROA (%)	x	-0,32	0,19	x	x	x	x	-0,15	x	x


B Dendrograms pro proměnné vstupující do klasifikace a struktury závislosti kopula modelu




Obr. 29 Dendrogram založený na analýzované volatilitě (rok 2013)




Obr. 30 Dendrogram založený na analýzované volatilitě (rok 2012)




Obr. 31 Dendrogram založený na analýzované volatilitě (rok 2011)




Obr. 32 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2011, 1. úroveň závislosti)




Obr. 33 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2011, 2. úroveň závislosti)




Obr. 34 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2011, 3. úroveň závislosti)




Obr. 35 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2012, 1. úroveň závislosti)



Obr. 36 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2012, 2. úroveň závislosti)




Obr. 37 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2012, 3. úroveň závislosti)




Obr. 38 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2013, 1. úroveň závislosti)



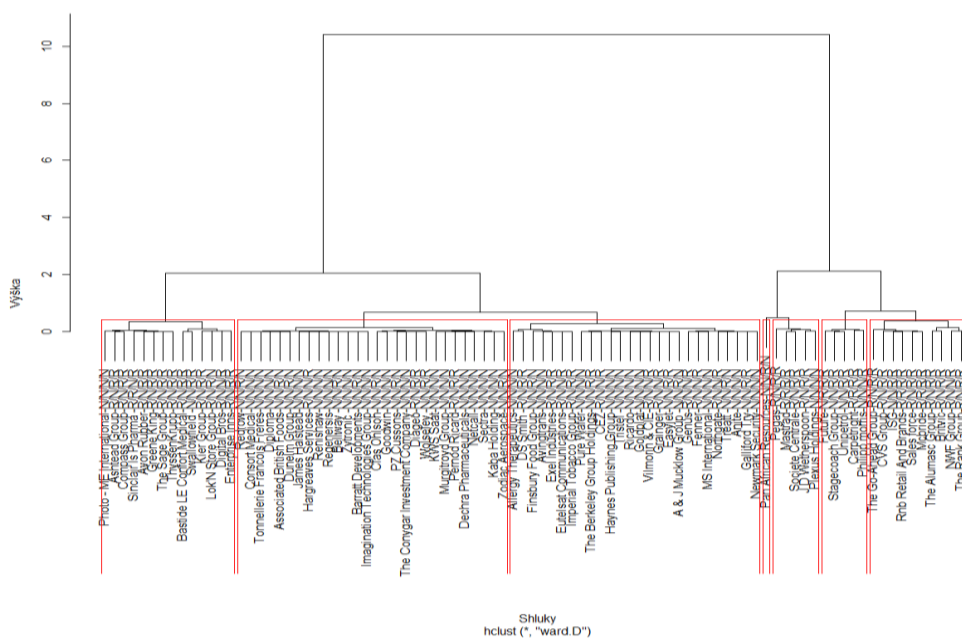
Obr. 39 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2013, 2. úroveň závislosti)




Obr. 40 Odhad D-Vine kopule na datech 90 společností (vstup pro r. 2013, 3. úroveň závislosti)




Obr. 41 Dendrogram založený na pravděpodobnostech z Altmanova modelu (rok 2014)




Obr. 42 Dendrogram založený na pravděpodobnostech z Ohlsonova modelu (rok 2014)




Obr. 43 Dendrogram založený na pravděpodobnostech z Altmanova modelu (rok 2013)



Obr. 44 Dendrogram založený na pravděpodobnostech z Ohlsonova modelu (rok 2013)



Obr. 47 Dendrogram založený na pravděpodobnostech z Altmanova modelu (rok 2011)



Obr. 48 Dendrogram založený na pravděpodobnostech z Ohlsonova modelu (rok 2011)

C Sumarizace vstupních dat a jiné

Tab. 43 Vstupní údaje pro odhad rizika pro 2014 (v Kč)

Společnost/vstupy	Tržní kapitalizace (vlastní kapitál)	Splatné dluhy	Anualizovaná volatilita	Tržní hodnota dluhů	Tržní hodnota aktiv	Anualizovaná volatilita aktiv	3-roční EU27 bez- riziková sazba
Associated British Foods PLC	27 845 279,04	3 912 938,66	21,0%	3 639 126,38	31 485 000,00	0,19	0,01
Allergy Therapeutics PLC	74 211,67	8 074,72	36,0%	7 507,46	81 718,00	0,32	
Ashtead Group Public Limited Company	6 740 961,85	1 060 741,55	23,0%	986 514,59	7 727 500,00	0,20	
Anite PLC	292 971,83	86 044,58	44,0%	80 018,74	3 718 500,00	0,44	
Mastrad	7 474,40	11 366,50	51,0%	9 789,30	17 228,00	0,25	
The Alumasc Group PLC	62 065,36	42 845,33	26,0%	36 190,73	62 066,00	0,26	
Avingtrans PLC	60 008,14	31 771,96	19,0%	29 548,58	89 557,00	0,12	
Avon Rubber P.L.C.	241 772,10	40 628,61	62,0%	35 399,53	277 250,00	0,55	
Barratt Developments P L C	4 497 952,78	1 544 747,23	19,0%	1 436 650,58	5 938 300,00	0,15	
The Berkeley Group Holdings PLC	3 614 382,28	1 593 319,19	21,0%	1 481 810,33	5 100 000,00	0,15	
Bastide LE Confort Medical	156 568,60	65 890,00	34,0%	61 069,72	217 779,00	0,24	
Britvic PLC	2 662 364,89	832 530,57	22,0%	774 264,39	3 436 700,00	0,17	
Bellway P L C	2 323 385,03	684 941,99	23,0%	637 004,61	2 960 000,00	0,18	
Societe Centrale DES Bois ET DSDLM	264 039,55	120 242,50	40,0%	109 367,71	349 220,00	0,30	
The Conygar Investment Company PLC	203 920,28	62 272,99	329,0%	32 767,19	236 760,00	0,89	
Clas Ohlson Aktiebolag	907 568,76	132 221,67	37,0%	122 847,55	1 037 000,00	0,33	
Compass Group PLC	16 488 665,11	6 113 056,14	20,0%	5 685 261,20	22 174 000,00	0,15	
Carpetright PLC	495 025,06	130 603,01	44,0%	120 112,59	615 130,00	0,35	
Sales force0	526 094,17	85 775,63	21,0%	79 773,38	606 070,00	0,18	
Consort Medical PLC	282 214,34	21 700,91	36,0%	20 180,95	330 245,00	0,34	
CVS Group PLC	276 605,36	57 517,68	37,0%	53 363,67	329 970,00	0,31	
Diageo PLC	56 289 615,66	11 035 910,16	22,0%	10 263 648,98	66 550 000,00	0,19	
Digital Bros S.P.A.	62 548,21	53 780,50	42,0%	48 625,81	111 100,00	0,25	
Dunelm Group PLC	622 651,01	115 215,12	22,0%	107 152,78	730 000,00	0,18	
Dechra Pharmaceuticals PLC	797 731,93	105 508,03	35,0%	98 082,02	896 060,00	0,31	
Diploma PLC	292 978,53	61 464,20	21,0%	57 163,16	350 260,00	0,17	
Enterprise Inns PLC	3 900 579,83	1 906 240,01	21,0%	1 772 802,62	5 677 000,00	0,15	
Eutelsat Communications	9 122 592,29	1 857 650,00	21,0%	108 550,00	108 550,00	0,17	
Exel Industries	453 322,86	340 182,50	20,0%	316 363,11	770 490,00	0,12	
Easyjet PLC	3 229 911,21	2 179 962,35	20,0%	2 027 364,32	5 260 000,00	0,12	
Fenner PLC	1 035 437,03	358 416,02	22,0%	333 331,68	1 369 600,00	0,17	
Finsbury Food Group PLC	56 578,73	48 909,54	34,0%	45 158,30	101 850,00	0,19	
Future PLC	26 065,22	34 846,86	64,0%	26 914,46	53 025,00	0,37	

Goldplat PLC	6 107,85	7 787,73	46,0%	6 909,91	13 031,00	0,24
Goodwin PLC	362 948,61	59 332,54	20,0%	55 180,68	418 260,00	0,17
Galliford Try PLC	657 718,94	1 018 258,46	22,0%	945 011,20	1 454 700,00	0,10
Greene King PLC	4 110 829,54	1 481 247,45	24,0%	1 377 553,47	5 491 900,00	0,17
Genus PLC	951 081,14	133 787,57	20,0%	124 425,63	1 075 800,00	0,18
The Go-Ahead Group PLC	809 381,85	997 805,51	21,0%	927 818,96	1 739 600,00	0,10
Grainger PLC	2 331 644,43	785 734,51	56,0%	688 053,89	3 020 900,00	0,44
Hargreaves Services PLC	403 352,91	208 435,08	21,0%	193 842,92	597 690,00	0,14
Haynes Publishing Group Public Limited Company	16 044,00	8 066,80	24,0%	7 501,05	23 563,00	0,16
Imagination Technologies Group PLC	643 876,42	71 870,12	23,0%	66 840,92	710 890,00	0,21
Imperial Tobacco Group PLC	37 704 323,23	14 745 820,42	21,0%	13 713 912,69	51 453 000,00	0,15
ISG PLC	30 901,17	554 383,69	27,0%	515 217,04	547 350,00	0,02
J D Wetherspoon PLC	1 355 492,01	612 150,00	27,0%	569 005,49	1 925 900,00	0,19
James Halstead PLC	675 124,08	71 079,95	23,0%	66 106,05	741 400,00	0,21
Kaba Holding AG	1 346 650,40	215 199,62	20,0%	200 140,79	1 547 300,00	0,17
Kier Group PLC	443 395,64	1 405 427,65	26,0%	1 306 037,61	1 751 500,00	0,06
KWS Saat AG	1 365 463,18	284 536,00	26,0%	264 617,43	1 630 800,00	0,22
Lok'N Store Group PLC	98 003,59	23 110,92	25,0%	21 493,33	119 550,00	0,20
Mcbride PLC	324 880,39	315 356,71	26,0%	293 176,30	681 861,00	0,14
A & J Mucklow Group P L C	418 489,62	62 692,90	24,0%	58 305,83	476 960,00	0,21
MS International PLC	24 860,72	18 490,96	25,0%	17 197,03	75 732,00	0,08
Murgitroyd Group PLC	71 634,90	9 502,74	25,0%	8 837,76	80 494,00	0,22
Netcall PLC	89 991,92	11 381,20	24,0%	10 584,75	68 768,00	0,20
Northgate PLC	1 259 313,14	308 208,12	28,0%	39 777,94	39 778,00	0,20
NWF Group PLC	76 056,49	71 072,97	27,0%	66 005,08	142 220,00	0,15
Newmark Security PLC	7 528,19	5 525,97	27,0%	5 133,35	12 673,00	0,16
Pan African Resources PLC	324 175,44	29 949,07	26,0%	27 853,34	352 100,00	0,24
Photo - ME International P L C	535 879,78	56 329,55	26,0%	52 387,76	588 400,00	0,24
Plexus Holdings PLC	302 536,96	9 414,01	27,0%	8 731,90	187 200,00	0,48
Pure Wafer PLC	23 224,49	5 615,75	26,0%	5 222,54	28 459,00	0,21
PZ Cussons PLC	1 797 141,76	417 151,81	25,0%	387 953,04	2 186 100,00	0,21
Ricardo PLC	401 875,13	75 084,71	26,0%	69 830,14	471 880,00	0,21
Redrow PLC	711 076,77	504 534,67	24,0%	469 085,68	1 181 300,00	0,14
Regeneris PLC	274 917,22	61 890,37	25,0%	57 559,29	332 620,00	0,19
Pernod Ricard	28 169 713,88	7 761 000,00	21,0%	7 217 902,52	35 406 000,00	0,17
Vilmorin & CIE	1 832 224,28	1 001 100,00	21,0%	931 013,56	2 765 500,00	0,14
Rnb Retail And Brands AB (Publ)	78 637,06	60 203,17	24,0%	55 990,39	36 287 000,00	0,23
The Rank Group PLC	687 668,90	304 616,14	25,0%	283 248,42	971 600,00	0,18
Renishaw P L C	1 449 898,44	50 142,12	20,0%	46 633,31	291 480,00	0,19
Sectra Aktiebolag	255 664,56	38 918,86	24,0%	36 195,44	291 950,00	0,21

Stagecoach Group PLC	2 500 500,37	1 353 828,47	24,0%	1 258 838,83	3 761 900,00	0,16
The Sage Group Plc.	4 575 562,30	1 437 101,66	25,0%	1 336 461,72	5 915 400,00	0,19
DS Smith PLC	2 161 388,05	2 039 008,25	24,0%	1 895 420,93	4 061 600,00	0,13
WH Smith PLC	953 404,38	369 885,35	23,0%	343 988,50	1 298 300,00	0,17
Sinclair Is Pharma PLC	244 710,96	58 466,21	23,0%	54 374,67	299 220,00	0,19
Swallowfield PLC	13 437,19	21 137,74	23,0%	19 658,60	418 908,00	0,22
Treant PLC	106 141,79	26 299,85	22,0%	24 459,40	130 660,00	0,18
Tonnellerie Francois Freres	330 591,81	86 583,50	22,0%	80 524,43	411 320,00	0,18
ThyssenKrupp AG	13 623 372,12	19 541 500,00	27,0%	18 143 590,50	31 811 000,00	0,11
Tristel PLC	37 136,92	3 514,70	23,0%	3 268,75	40 412,00	0,21
Wolseley PLC	8 594 369,19	3 712 941,53	23,0%	3 452 908,40	12 056 000,00	0,17
Zodiac Aerospace	5 152 035,54	1 806 603,50	22,0%	1 680 168,25	6 836 500,00	0,16
Zytronic PLC	41 249,90	4 488,05	22,0%	4 173,99	45 434,00	0,20
CEZ	15 459 161,79	3 068 908,27	26,0%	2 854 157,27	18 321 000,00	0,18
Unipetrol	1 197 490,33	36 448,71	22,0%	33 898,17	2 381 730,00	0,16
Philipp morris	556 098,34	1 587 330,03	23,0%	1 475 352,07	2 035 200,00	0,06
Pegas	2 993 473,60	5 757,02	24,0%	5 354,16	817 937,15	0,21

Tab. 44 Vstupní údaje pro odhad rizika pro 2013 (v Kč)

Společnost/vstupy	Tržní kapitalizace (vlastní kapitál)	Splatné dluhy	Anualizovaná volatilita	Tržní hodnota dluhů	Tržní hodnota aktiv	Anualizovaná volatilita aktiv	3-roční EU27 bezriziková sazba
Associated British Foods PLC	18 725 529,50	3 593 544,23	22,0%	3 044 992,69	21 777 000,00	0,19	0,03
Allergy Therapeutics PLC	46 385,56	9 007,20	31,0%	7 630,71	54 009,00	0,27	
Ashtead Group Public Limited Company	4 715 550,60	911 602,71	58,0%	738 803,96	5 457 500,00	0,50	
Anite PLC	437 666,56	91 444,67	41,0%	77 485,75	5 140 000,00	0,35	
Mastrad	16 708,61	10 130,00	47,0%	8 186,67	24 975,00	0,34	
The Alumasc Group PLC	48 058,18	45 454,40	25,0%	38 475,62	86 548,00	0,15	
Avingtrans PLC	40 067,81	28 938,85	17,0%	24 521,33	64 591,00	0,11	
Avon Rubber P.L.C.	215 117,91	33 524,02	56,0%	27 579,95	242 710,00	0,50	
Barratt Developments P L C	3 624 861,28	1 609 525,10	66,0%	1 168 328,84	4 807 900,00	0,53	
The Berkeley Group Holdings PLC	3 197 234,36	1 232 042,33	34,0%	1 041 713,99	4 230 000,00	0,25	
Bastide LE Confort Medical	97 821,30	56 093,00	32,0%	47 377,70	145 230,00	0,22	
Britvic PLC	2 226 549,85	953 223,37	33,0%	805 817,85	3 032 900,00	0,24	
Bellway P L C	1 967 483,14	449 623,09	41,0%	379 174,88	2 383 900,00	0,34	
Societe Centrale DES Bois ET DSDLM	200 021,77	101 392,00	37,0%	85 304,13	285 340,00	0,26	
The Conygar Investment Company PLC	186 685,13	53 488,22	268,0%	26 445,05	213 100,00	0,90	
Clas Ohlson Aktiefbolag	597 216,45	127 416,39	35,0%	107 871,74	705 000,00	0,29	
Compass Group PLC	19 859 414,22	5 269 999,81	27,0%	4 465 060,52	24 332 500,00	0,22	
Carpetright PLC	516 083,36	148 899,54	41,0%	125 174,41	641 270,00	0,33	

Sales force0	670 463,40	72 402,60	24,0%	61 350,42	731 850,00	0,22
Consort Medical PLC	233 553,40	56 593,83	33,0%	47 919,11	281 150,00	0,27
CVS Group PLC	161 118,82	51 168,15	34,0%	43 273,22	204 400,00	0,27
Diageo PLC	65 521 245,64	11 222 660,12	21,0%	9 509 534,17	75 032 000,00	0,19
Digital Bros S.P.A.	50 969,79	54 864,50	42,0%	45 211,90	96 186,00	0,23
Dunelm Group PLC	622 651,01	135 614,19	37,0%	114 676,87	737 330,00	0,31
Dechra Pharmaceuticals PLC	800 994,12	192 217,34	33,0%	162 737,57	963 700,00	0,28
Diploma PLC	258 407,70	52 268,50	42,0%	44 036,20	302 450,00	0,36
Enterprise Inns PLC	3 889 802,16	2 124 737,26	68,0%	1 471 117,52	5 040 000,00	0,52
Eutelsat Communications	7 407 385,83	1 534 550,00	24,0%	1 300 298,04	8 708 500,00	0,20
Exel Industries	290 097,47	217 990,50	31,0%	184 181,38	474 300,00	0,19
Easyjet PLC	5 393 512,77	2 167 800,76	43,0%	1 809 768,88	7 180 000,00	0,32
Fenner PLC	920 026,30	335 862,73	50,0%	274 287,13	1 190 000,00	0,39
Finsbury Food Group PLC	54 679,29	57 686,05	36,0%	48 294,69	103 000,00	0,20
Future PLC	61 089,97	53 930,91	60,0%	36 587,21	87 667,00	0,45
Goldplat PLC	12 307,24	4 920,41	45,0%	4 084,49	16 387,00	0,34
Goodwin PLC	199 956,18	53 478,95	37,0%	45 186,72	245 000,00	0,30
Galliford Try PLC	923 213,14	854 905,19	51,0%	676 996,60	1 606 200,00	0,32
Greene King PLC	3 605 601,64	1 331 103,24	35,0%	1 123 045,35	4 746 000,00	0,28
Genus PLC	1 036 992,37	121 852,47	31,0%	103 248,90	1 140 300,00	0,28
The Go-Ahead Group PLC	853 397,02	824 729,96	33,0%	694 847,84	1 558 800,00	0,18
Grainger PLC	2 014 073,28	1 026 408,99	50,0%	834 713,36	2 860 600,00	0,36
Hargreaves Services PLC	439 270,13	269 146,26	36,0%	226 392,68	669 100,00	0,24
Haynes Publishing Group Public Limited Company	5 726,92	6 406,82	11,0%	5 428,82	11 240,00	0,06
Imagination Technologies Group PLC	1 288 019,50	117 678,35	60,0%	92 729,79	650 450,00	0,54
Imperial Tobacco Group PLC	37 666 630,17	18 472 218,29	25,0%	15 650 327,96	52 453 000,00	0,17
ISG PLC	33 720,80	465 514,31	28,0%	394 250,93	433 930,00	0,02
J D Wetherspoon PLC	1 580 598,32	566 531,58	38,0%	146 038,12	150 048,00	0,32
James Halstead PLC	622 458,51	72 467,39	37,0%	61 405,33	6 287 200,00	0,36
Kaba Holding AG	1 052 216,64	242 749,97	26,0%	205 691,58	1 257 900,00	0,21
Kier Group PLC	481 593,56	914 379,34	37,0%	765 388,36	1 257 800,00	0,15
KWS Saat AG	1 866 381,35	222 715,00	36,0%	188 671,62	2 058 000,00	0,32
Lok'N Store Group PLC	64 200,86	24 199,09	24,0%	20 504,42	85 027,00	0,18
Mcbride PLC	339 393,41	323 351,98	44,0%	265 557,87	608 600,00	0,26
A & J Mucklow Group P L C	348 738,48	54 094,33	45,0%	45 836,77	616 900,00	0,27
MS International PLC	30 480,30	19 276,63	33,0%	16 280,28	46 994,00	0,21
Murgitroyd Group PLC	52 486,96	9 655,04	20,0%	8 181,21	60 722,00	0,16
Netcall PLC	44 736,48	11 080,54	26,0%	9 389,00	54 273,00	0,20
Northgate PLC	967 015,44	232 088,97	63,0%	182 890,23	1 283 200,00	0,54
NWF Group PLC	76 056,49	78 320,92	42,0%	65 367,42	164 062,00	0,24

Newmark Security PLC	7 117,27	4 469,11	23,0%	3 786,49	10 942,00	0,15
Pan African Resources PLC	268 302,81	28 257,31	61,0%	23 219,00	291 520,00	0,55
Photo - ME International P L C	272 801,50	57 004,76	67,0%	43 799,90	316 600,00	0,58
Plexus Holdings PLC	191 141,25	8 977,60	37,0%	7 607,18	311 310,00	0,26
Pure Wafer PLC	15 764,25	7 422,07	72,0%	5 101,59	20 907,00	0,57
PZ Cussons PLC	1 882 326,22	347 421,02	34,0%	258 015,56	2 078 700,00	0,64
Ricardo PLC	232 698,48	60 351,77	33,0%	51 090,80	283 000,00	0,27
Redrow PLC	1 053 413,09	369 076,23	49,0%	302 853,11	1 354 600,00	0,39
Regeneris PLC	121 609,96	43 765,01	24,0%	37 083,20	158 700,00	0,18
Pernod Ricard	31 284 811,17	8 569 500,00	30,0%	7 260 087,47	38 618 000,00	0,23
Vilmorin & CIE	2 007 284,83	905 300,00	28,0%	767 085,20	2 965 500,00	0,17
Rnb Retail And Brands AB (Publ)	77 684,34	89 517,47	262,0%	75 852,74	2 765 600,00	0,14
The Rank Group PLC	825 774,18	242 913,04	39,0%	204 692,46	1 030 500,00	0,31
Renishaw P L C	1 290 055,43	51 398,81	45,0%	43 467,43	309 150,00	0,33
Sectra Aktiebolag	159 445,87	43 199,32	39,0%	36 441,94	195 890,00	0,32
Stagecoach Group PLC	2 757 918,64	1 354 143,57	36,0%	1 141 599,07	3 916 900,00	0,25
The Sage Group Plc.	4 785 041,38	1 069 783,76	28,0%	906 476,85	5 782 500,00	0,20
DS Smith PLC	3 556 678,39	1 538 944,63	48,0%	1 259 063,81	4 816 500,00	0,37
WH Smith PLC	1 187 678,94	337 114,61	28,0%	285 595,49	1 473 300,00	0,23
Sinclair Is Pharma PLC	143 375,87	34 399,36	44,0%	28 848,26	172 230,00	0,37
Swallowfield PLC	10 242,57	22 145,24	10,0%	18 764,80	241 122,00	0,05
Treatt PLC	84 697,41	18 778,58	15,0%	15 912,05	108 000,00	0,17
Tonnellerie Francois Freres	273 316,99	79 202,00	23,0%	67 111,65	340 440,00	0,18
ThyssenKrupp AG	14 341 565,05	18 076 000,00	43,0%	14 824 460,17	29 298 000,00	0,23
Tristel PLC	9 261,52	2 186,05	25,0%	1 852,32	11 114,00	0,21
Wolseley PLC	10 590 950,53	3 610 214,87	50,0%	2 949 676,21	13 542 000,00	0,40
Zodiac Aerospace	6 996 768,77	1 277 034,50	34,0%	1 081 398,09	8 078 300,00	0,30
Zytronic PLC	25 916,53	4 064,52	25,0%	3 444,05	29 360,00	0,23
CEZ	21 031 882,53	7 865 837,08	28,0%	6 664 265,10	27 695 000,00	0,20
Unipetrol	1 246 431,19	686 634,01	30,0%	581 730,17	2 748 150,00	0,21
Philipp morris	3 312 768,51	1 777 959,92	28,0%	1 506 556,52	4 818 200,00	0,08
Pegas	3 350 313,15	82 621,86	28,0%	70 008,72	695 246,58	0,26

Tab. 45 Vstupní údaje pro odhad rizika pro 2012 (v Kč)

Společnost/vstupy	Tržní kapitalizace	Splatné dluhy	Anualizovaná volatilita	Tržní hodnota dluhů	Tržní hodnota aktiv	Anualizovaná volatilita aktiv	3-roční EU27 bez-riziková sazba
Associated British Foods PLC	14 106 932,13	3 758 689,86	22,0%	3 384 214,09	17 493 000,00	0,18	0,02
Allergy Therapeutics PLC	39 851,17	16 446,45	28,0%	14 799,29	54 656,00	0,21	

Ashtead Group Public Limited Company	2 590 524,17	791 062,69	54,0%	678 054,24	3 270 000,00	0,44
Anite PLC	435 599,52	61 905,99	42,0%	55 738,55	4 941 000,00	0,38
Mastrad	18 127,32	12 956,00	47,0%	11 595,55	29 326,00	0,21
The Alumasc Group PLC	47 517,67	44 414,01	24,0%	38 389,00	85 916,00	0,14
Avingtrans PLC	32 359,88	22 717,37	16,0%	20 454,10	51 611,00	0,10
Avon Rubber P.L.C.	130 861,43	33 872,20	51,0%	29 563,69	160 520,00	0,42
Barratt Developments P L C	1 920 735,16	1 481 231,31	61,0%	1 155 893,74	3 081 000,00	0,42
The Berkeley Group Holdings PLC	2 140 817,87	1 257 348,39	33,0%	1 128 391,84	3 274 700,00	0,21
Bastide LE Confort Medical	82 799,38	49 134,50	31,0%	44 151,49	126 970,00	0,20
Britvic PLC	1 745 668,43	796 697,26	31,0%	715 933,45	2 461 900,00	0,22
Bellway P L C	1 321 931,96	494 615,77	39,0%	441 524,95	1 763 600,00	0,30
Societe Centrale DES Bois ET DSDLM	187 024,77	107 300,50	34,0%	96 095,48	283 580,00	0,23
The Conygar Investment Company PLC	165 881,07	45 902,59	283,0%	24 028,99	189 970,00	0,90
Clas Ohlson Aktiebolag	657 319,43	131 117,66	33,0%	118 026,62	1 020 900,00	0,29
Compass Group PLC	17 209 100,28	5 081 525,09	26,0%	4 574 817,65	20 795 000,00	0,20
Carpetright PLC	522 039,02	176 845,37	39,0%	157 981,84	680 700,00	0,30
Sales force0	516 143,97	75 836,53	26,0%	68 281,03	584 450,00	0,23
Consort Medical PLC	283 033,72	59 784,22	30,0%	53 815,64	336 870,00	0,25
CVS Group PLC	128 597,28	41 050,60	30,0%	36 941,73	165 500,00	0,23
Diageo PLC	60 634 412,83	9 705 774,81	21,0%	8 738 827,47	69 337 700,00	0,18
Digital Bros S.P.A.	57 398,79	64 386,50	41,0%	56 551,39	113 970,00	0,22
Dunelm Group PLC	1 221 379,15	137 183,71	35,0%	123 488,85	1 344 900,00	0,32
Dechra Pharmaceuticals PLC	630 695,92	159 280,57	31,0%	143 331,94	774 090,00	0,25
Diploma PLC	199 223,52	60 481,46	40,0%	54 408,69	253 600,00	0,25
Enterprise Inns PLC	3 826 442,66	2 148 859,50	62,0%	1 702 929,37	5 529 000,00	0,45
Eutelsat Communications	7 690 465,64	1 456 081,00	24,0%	1 311 014,40	9 002 100,00	0,20
Exel Industries	223 015,04	191 990,00	29,0%	172 469,05	396 320,00	0,16
Easyjet PLC	2 806 206,46	2 243 982,67	41,0%	1 978 841,88	4 799 390,00	0,25
Fenner PLC	967 606,94	334 508,52	47,0%	293 513,05	1 260 000,00	0,37
Finsbury Food Group PLC	55 559,58	81 948,04	36,0%	72 851,09	128 740,00	0,16
Future PLC	64 043,06	76 073,79	58,0%	60 765,22	125 000,00	0,33
Goldplat PLC	21 301,70	7 849,47	45,0%	6 941,00	28 312,00	0,34
Goodwin PLC	131 976,94	50 565,05	38,0%	45 238,93	177 000,00	0,28
Galliford Try PLC	619 798,04	921 308,23	47,0%	792 169,06	1 410 000,00	0,22
Greene King PLC	3 203 373,79	1 200 524,59	32,0%	1 079 130,28	4 287 800,00	0,24
Genus PLC	997 239,97	124 587,69	30,0%	112 172,11	1 110 000,00	0,27
The Go-Ahead Group PLC	750 115,34	846 968,45	31,0%	759 306,07	1 513 100,00	0,15
Grainger PLC	2 054 741,89	1 344 534,16	46,0%	1 167 269,98	3 227 200,00	0,30
Hargreaves Services PLC	362 236,86	237 195,62	34,0%	212 342,73	575 600,00	0,22
Haynes Publishing Group Public Limited Company	7 782,34	5 756,34	11,0%	5 182,02	8 000,00	0,07

Imagination Technologies Group PLC	2 160 524,10	36 168,15	59,0%	32 165,62	470 989,00	0,51
Imperial Tobacco Group PLC	39 632 298,49	16 123 956,28	24,0%	14 514 110,60	53 453 000,00	0,19
ISG PLC	24 621,28	436 583,80	27,0%	356 872,24	357 789,00	0,03
J D Wetherspoon PLC	1 336 453,93	547 359,64	36,0%	169 814,54	174 006,00	0,29
James Halstead PLC	649 936,34	71 075,29	41,0%	63 895,35	711 030,00	0,37
Kaba Holding AG	1 132 070,48	269 855,98	24,0%	242 968,96	1 376 000,00	0,20
Kier Group PLC	456 311,12	1 070 571,21	34,0%	954 679,58	1 415 000,00	0,12
KWS Saat AG	1 259 703,23	221 262,00	34,0%	199 115,83	1 459 800,00	0,29
Lok'N Store Group PLC	67 778,11	5 256,70	23,0%	4 732,99	74 098,00	0,15
Mcbride PLC	380 178,81	338 897,83	43,0%	290 075,85	550 789,00	0,24
A & J Mucklow Group P L C	360 693,01	49 163,26	43,0%	44 100,66	405 010,00	0,38
MS International PLC	54 630,34	19 950,30	30,0%	12 745,08	18 256,00	0,34
Murgitroyd Group PLC	39 801,62	11 797,09	17,0%	10 621,79	40 950,00	0,10
Netcall PLC	30 882,12	9 833,98	27,0%	8 853,32	39 778,00	0,20
Northgate PLC	800 297,94	594 174,94	58,0%	480 937,32	1 260 000,00	0,38
NWF Group PLC	76 282,59	71 878,50	38,0%	63 734,44	140 310,00	0,21
Newmark Security PLC	4 875,41	7 369,16	23,0%	6 633,42	11 539,00	0,09
Pan African Resources PLC	253 686,53	13 709,32	60,0%	12 181,57	265 870,00	0,57
Photo - ME International P L C	140 977,90	64 158,64	61,0%	57 721,54	311 310,00	0,26
Plexus Holdings PLC	121 331,69	9 844,42	44,0%	8 849,78	130 220,00	0,41
Pure Wafer PLC	17 737,27	13 705,13	73,0%	7 492,00	20 788,00	0,63
PZ Cussons PLC	1 764 772,83	411 610,76	32,0%	370 391,79	2 137 000,00	0,26
Ricardo PLC	209 960,74	68 397,12	32,0%	61 525,66	271 179,00	0,24
Redrow PLC	571 434,33	334 098,39	46,0%	288 679,97	1 181 300,00	0,39
Regeneris PLC	54 390,56	30 604,84	26,0%	27 555,81	254 040,00	0,17
Pernod Ricard	30 701 459,77	6 173 000,00	27,0%	5 557 804,31	36 280 000,00	0,23
Vilmorin & CIE	1 755 649,60	884 650,00	27,0%	796 250,90	2 565 500,00	0,18
Rnb Retail And Brands AB (Publ)	114 591,64	101 598,95	239,0%	91 477,06	36 287 000,00	0,05
The Rank Group PLC	514 834,19	290 306,93	38,0%	244 962,43	606 540,00	0,32
Renishaw P L C	1 236 730,02	69 872,69	42,0%	57 886,80	181 962,00	0,40
Sectra Aktiebolag	102 201,76	35 057,91	37,0%	31 408,33	133 760,00	0,28
Stagecoach Group PLC	2 419 740,88	1 169 472,83	33,0%	1 049 667,37	3 474 000,00	0,23
The Sage Group Plc.	5 008 595,00	1 097 089,69	26,0%	987 766,71	6 031 500,00	0,22
DS Smith PLC	1 505 337,21	989 828,13	45,0%	864 093,25	2 373 300,00	0,29
WH Smith PLC	935 705,10	370 510,25	27,0%	333 477,63	1 270 800,00	0,20
Sinclair Is Pharma PLC	144 698,90	29 314,40	42,0%	26 233,12	171 060,00	0,36
Swallowfield PLC	16 721,07	23 015,89	10,0%	20 722,91	239 484,00	0,09
Treant PLC	61 231,91	26 501,46	15,0%	23 861,22	130 660,00	0,17
Tonnellerie Francois Freres	200 420,00	64 601,50	22,0%	58 165,01	258 870,00	0,17
ThyssenKrupp AG	13 598 366,02	21 872 000,00	41,0%	19 204 212,84	32 845 000,00	0,18

Tristel PLC	13 949,12	2 551,68	29,0%	2 297,24	16 257,00	0,25
Wolseley PLC	8 539 018,66	3 736 313,59	46,0%	3 271 627,47	11 826 000,00	0,34
Zodiac Aerospace	4 876 759,82	1 374 230,50	31,0%	1 236 071,75	6 836 500,00	0,27
Zytronic PLC	57 872,45	4 861,20	28,0%	4 376,90	62 270,00	0,25
CEZ	22 130 807,49	7 922 530,23	28,0%	7 132 488,90	29 297 000,00	0,19
Unipetrol	1 218 818,67	843 187,46	27,0%	758 832,64	2 564 940,00	0,19
Philipp morris	3 047 417,02	1 857 349,67	26,0%	1 672 309,43	4 726 900,00	0,07
Pegas	3 081 986,74	61 510,54	26,0%	55 382,49	736 143,43	0,24

Tab. 46 Praviděpodobnosti defaultu na základě Mertonova D-Vine kopula modelu pro všechny společnosti

Firmy	2014	2013	2012	Firmy	2014	2013	2012
Associated British Foods PLC	1,60%	2,00%	1,80%	J D Wetherspoon PLC	2,10%	93,30%	95,80%
Allergy Therapeutics PLC	3,60%	2,90%	3,40%	James Halstead PLC	1,80%	5,40%	4,40%
Ashtead Group Public Limited Company	1,80%	7,70%	7,50%	Kaba Holding AG	1,20%	2,30%	2,50%
Anite PLC	5,40%	5,10%	4,20%	Kier Group PLC	0,70%	3,00%	3,50%
Mastrad	5,60%	3,70%	6,30%	KWS Saat AG	2,20%	4,00%	4,10%
The Alumasc Group PLC	6,20%	2,20%	2,40%	Lok'N Store Group PLC	1,90%	0,90%	2,00%
Avingtrans PLC	0,80%	0,80%	1,00%	Mcbride PLC	1,50%	6,10%	5,30%
Avon Rubber P.L.C.	8,10%	7,00%	7,40%	A & J Mucklow Group PLC	1,90%	5,60%	3,10%
Barratt Developments P L C	1,20%	9,30%	9,30%	MS International PLC	0,30%	17,10%	3,40%
The Berkeley Group Holdings PLC	1,30%	3,30%	3,60%	Murgitroyd Group PLC	2,00%	0,60%	1,20%
Bastide LE Confort Medical	2,90%	3,10%	3,40%	Netcall PLC	1,80%	2,50%	2,20%
Britvic PLC	1,50%	3,30%	3,50%	Northgate PLC	99,90%	8,50%	8,20%
Bellway P L C	1,70%	5,00%	4,90%	NWF Group PLC	1,90%	4,30%	4,40%
Societe Centrale DES Bois ET DES Scieries De LA Manche	4,50%	3,90%	4,10%	Newmark Security PLC	1,90%	1,10%	1,80%
The Conygar Investment Company PLC	13,40%	13,60%	13,10%	Pan African Resources PLC	2,20%	8,60%	7,90%
Clas Ohlson Aktiebolag	3,90%	3,90%	3,80%	Photo-ME International P L C	2,20%	3,60%	8,90%
Compass Group PLC	1,20%	2,50%	2,70%	Plexus Holdings PLC	6,20%	5,90%	2,80%
Carpentryright PLC	4,90%	4,90%	4,90%	Pure Wafer PLC	2,10%	14,50%	10,20%
Sales force0	1,40%	2,70%	2,30%	PZ Cussons PLC	2,00%	3,60%	9,70%
Consort Medical PLC	3,80%	3,20%	3,60%	Ricardo PLC	2,00%	3,40%	3,60%
CVS Group PLC	3,80%	3,10%	3,80%	Redrow PLC	1,40%	6,90%	6,40%
Diageo PLC	1,70%	1,80%	1,80%	Regeneris PLC	1,70%	1,50%	2,00%
Digital Bros S.P.A.	4,20%	5,00%	4,80%	Pernod Ricard	1,40%	2,80%	2,90%
Dunelm Group PLC	1,40%	4,40%	4,20%	Vilmorin & CIE	1,20%	2,40%	1,90%
Dechra Pharmaceuticals PLC	3,50%	3,40%	3,70%	Rnb Retail And Brands AB (Publ)	1,90%	0,10%	0,70%

Diploma PLC	1,30%	3,60%	5,10%	The Rank Group PLC	1,90%	6,90%	4,50%
Enterprise Inns PLC	1,40%	9,00%	10,00%	Renishaw P L C	1,70%	8,10%	4,50%
Eutelsat Communications	100,00%	2,20%	2,10%	Sectra Aktiebolag	1,90%	4,50%	4,60%
Exel Industries	1,00%	2,60%	3,00%	Stagecoach Group PLC	1,60%	3,60%	3,80%
Easyjet PLC	1,00%	5,10%	5,00%	The Sage Group PLC.	1,90%	2,70%	2,10%
Fenner PLC	1,60%	6,30%	6,40%	DS Smith PLC	1,40%	5,60%	6,30%
Finsbury Food Group PLC	2,70%	3,60%	3,80%	WH Smith PLC	1,60%	2,70%	2,90%
Future PLC	8,90%	8,60%	10,50%	Sinclair Is Pharma PLC	1,70%	5,50%	5,40%
Goldplat PLC	4,90%	5,80%	5,50%	Swallowfield PLC	1,90%	0,30%	0,10%
Goodwin PLC	1,20%	4,60%	4,20%	Treatt PLC	1,60%	1,80%	1,40%
Galliford Try PLC	1,30%	5,80%	6,80%	Tonnellerie Francois Freres	1,60%	2,00%	1,90%
Greene King PLC	1,60%	3,60%	4,10%	ThyssenKrupp AG	1,30%	4,60%	5,10%
Genus PLC	1,40%	3,40%	3,40%	Tristel PLC	1,80%	2,30%	2,50%
The Go-Ahead Group PLC	0,90%	2,70%	3,20%	Wolseley PLC	1,70%	7,30%	6,50%
Grainger PLC	6,90%	5,90%	6,40%	Zodiac Aerospace	1,40%	4,50%	3,90%
Hargreaves Services PLC	1,20%	3,80%	3,90%	Zytronic PLC	1,70%	2,40%	2,70%
Haynes Publishing Group Public Limited Company	1,60%	0,80%	0,30%	CEZ	1,40%	2,60%	2,70%
Imagination Technologies Group PLC	1,80%	7,70%	8,20%	Unipetrol	0,90%	2,80%	2,70%
Imperial Tobacco Group PLC	1,20%	2,50%	2,10%	Philipp morris	0,60%	0,50%	0,40%
ISG PLC	0,10%	3,70%	0,20%	Pegas	1,60%	3,20%	3,10%

Tab. 47 Dostupné proměnné z databáze Amadeus

Fixed Assets	Dlouhodobý majetek
Intangible Fixed Assets	Dlouhodobý nehmotný majetek
Tangible Fixed Assets	Dlouhodobý hmotný majetek
Other Fixed Assets	Dlouhodobý finanční majetek
Current Assets	Oběžná aktiva + časové rozlišení
Stocks	Zásoby
Debtors	Dlouhodobé pohledávky z obchodních vztahů + Krátkodobé pohledávky z obchodních vztahů
Other Current Assets	Jiné dl. pohledávky + Jiné krát. pohledávky + Čas. rozlišení
Cash and Cash Equivalent	Krátkodobý finanční majetek
Total Assets	Aktiva celkem
Shareholders' Funds	Vlastní kapitál
Capital	Základní kapitál

Other Shareholders Funds	Kapitálové fondy + Rezervní fondy, nedělitelný fond a ostatní fondy ze zisku + Výsledek hospodaření minulých let + Výsledek hospodaření běžného účetního období
inc. Reserves)	Dlouhodobé závazky + Bankovní úvěry dlouhodobé
Non-Current Liabilities	Bankovní úvěry dlouhodobé
Long Term Debt	Dlouhodobé závazky
Other non-Current Liabilities	Nemá přiřazený ekvivalent v české rozvaze.
Provisions	Závazky z obchodních vztahů + Krátkodobé bankovní úvěry + Krátkodobé finanční výpomoci + čas. rozlišení
Current Liabilities	Krátkodobé bankovní úvěry
Loans	Závazky z obchodních vztah
Creditors	Jiné závazky + Krátkodobé finanční výpomoci + čas. rozl.
Other Current Liab.	Pasiva celkem
Total Sh.Funds and Liab.	Zásoby + Krátkodobé pohledávky-Obchodní závazky
Working Capital	Krátkodobá aktiva - Krátkodobé závazky
Net current assets	Odhad celkové tržní hodnoty u kotovaných společností.
Enterprise Value	Počet zaměstnanců
Number of Empl.	Tržby za prodej zboží + Výkony + Ostatní provozní výnosy + Tržby z prodeje dlouhodobého majetku a materiálu + Převod provozních výnosů+ Změna stavu rezerv a opravných položek provozní oblasti
Sales	Tržby za prodej zboží + tržby za prodej vl. výrobků a služeb
Cost of Goods Sold	Neexistuje ekvivalent – pouze pro IFRS
Gross Profit	Neexistuje ekvivalent – pouze pro IFRS
Other Operating Expenses	Neexistuje ekvivalent – pouze pro IFRS
Operating Profit (Loss)	Provozní výsledek hospodaření
Financial Revenue	Výnosy z dlouhodobého finančního majetku + Výnosy z krátkodobého finančního majetku + Výnosy z přecenění CP a derivát + Výnosové úroky + Ostatní finanční výnosy + Převod finančních výnos + Tržby z prodeje CP a podíl
Financial Expenses	Jiné finanční náklady + Náklady z přecenění cenných papír a derivát + Nákladové úroky + Převod finančních náklad
Financial Profit / Loss	Finanční výsledek hospodaření
Profit (Loss) bef. Taxation	Provozní výsledek hospodaření + Finanční výsledek hospodaření
Taxation	Daň z příjmů za běžnou činnost
Profit (Loss) after Taxation	Výsledek hospodaření za běžnou činnost

Extraordinary +Other Revenue	Mimořádné výnosy
Extraordinary + Other Exp.	Mimořádné náklady
Extraordinary and Profit (Loss)	Mimořádný výsledek hospodaření
Profit (Loss) for Period	Výsledek hospodaření za účetní období
Export turnover	Neexistuje ekvivalent – pouze pro IFRS
Material Costs	Výkonová spotřeba + Nákl. vynaložené na prod. zboží - Služby
Cost of Employees	Osobní náklady
Depreciation	Odpisy dlouhodobého nehmotného a hmotného majetku
Interest Paid	Nákladové úroky
R&D expenses	Neexistuje ekvivalent - pouze pro IFRS
Cash Flow	Výsledek hospodaření za účetní období + Odpisy
Added Value	Daň z příjmů za běžnou činnost + Výsledek hospodaření za účetní období + Odpisy + Osobní náklady
EBIT	Provozní výsledek hospodaření
EBITDA	Provozní výsledek hospodaření + Odpisy

Tab. 48 Výsledky odhadnuté pravděpodobnosti účetních modelů (zleva od r. 2011 do r. 2014)

Společnosti	Ohlson pst.	Ohlson pst.	Ohlson pst.	Ohlson pst.	Altman pst.	Altman pst.	Altman pst.	Altman pst.
Associated British Foods	0,60%	0,70%	0,80%	0,70%	0,70%	1,20%	2,30%	1,40%
Allergy Therapeutics	9,30%	12,10%	10,70%	10,70%	80,70%	85,60%	63,80%	76,70%
Ashtead Group	12,20%	14,40%	16,60%	14,30%	5,60%	9,90%	11,50%	9,00%
Anite	4,40%	4,80%	3,30%	4,10%	1,20%	1,10%	2,40%	1,60%
Mastrad	66,20%	25,70%	17,60%	34,40%	20,60%	16,70%	6,80%	14,70%
The Alumasc Group	33,50%	29,60%	34,50%	32,50%	6,20%	7,00%	8,00%	7,10%
Avingtrans	7,30%	8,50%	10,20%	8,60%	6,50%	9,80%	9,70%	8,70%
Avon Rubber	12,80%	18,90%	13,10%	14,70%	0,00%	0,00%	0,00%	0,00%
Barratt Developments	0,30%	0,50%	0,50%	0,40%	4,40%	8,30%	10,30%	7,70%
The Berkeley Group Holdings	3,00%	0,70%	1,00%	1,30%	1,60%	1,90%	2,50%	2,00%
Bastide LE Confort Medical	21,80%	18,80%	17,30%	19,30%	7,10%	6,30%	5,00%	6,10%
Britvic	35,20%	47,20%	47,00%	43,10%	5,90%	7,30%	8,60%	7,30%
Bellway	0,20%	0,20%	0,20%	0,20%	1,10%	1,20%	2,40%	1,60%
Societe Centrale	66,40%	35,00%	22,90%	40,50%	31,60%	29,80%	27,10%	29,50%
The Conygar Investment Company	2,10%	2,00%	2,80%	2,30%	15,20%	16,50%	32,30%	21,30%
Clas Ohlson	2,50%	2,50%	2,20%	2,40%	0,00%	0,00%	0,00%	0,00%
Compass Group	12,00%	6,80%	5,10%	7,50%	3,30%	3,50%	4,90%	3,90%

Carpetright	51,10%	51,30%	44,80%	49,10%	3,50%	3,70%	2,80%	3,30%
Sales force	38,90%	44,00%	55,10%	45,90%	0,00%	0,00%	0,00%	0,00%
Consort Medical	0,90%	1,70%	6,90%	2,20%	0,10%	0,40%	5,40%	2,00%
CVS Group	40,20%	41,90%	47,50%	43,20%	1,50%	2,00%	2,50%	2,00%
Diageo	2,10%	2,30%	2,70%	2,30%	2,60%	3,80%	6,60%	4,30%
Digital Bros	19,60%	21,40%	18,20%	19,70%	4,80%	6,70%	3,10%	4,90%
Dunelm Group	0,60%	0,50%	0,50%	0,50%	1,20%	0,00%	0,10%	0,40%
Dechra Pharmaceuticals	1,70%	8,60%	10,10%	5,30%	0,40%	10,00%	9,20%	6,50%
Diploma	0,70%	0,70%	0,90%	0,80%	0,00%	0,00%	0,20%	0,10%
Enterprise Inns	18,60%	19,00%	17,70%	18,40%	25,80%	25,80%	27,90%	26,50%
Eutelsat Communications	7,00%	5,10%	5,70%	5,90%	19,40%	12,50%	8,20%	13,40%
Exel Industries	6,60%	6,20%	3,30%	5,20%	8,30%	8,50%	5,10%	7,30%
Easyjet	3,30%	3,60%	4,70%	3,80%	5,00%	8,80%	14,90%	9,60%
Fenner	5,70%	5,30%	5,60%	5,50%	6,80%	5,60%	5,70%	6,10%
Finsbury Food Group	8,10%	10,70%	27,30%	13,60%	5,30%	5,20%	8,20%	6,20%
Future	48,10%	13,30%	24,30%	26,40%	88,80%	36,10%	40,10%	55,00%
Goldplat	3,50%	6,90%	0,50%	2,30%	7,20%	1,30%	3,30%	4,00%
Goodwin	2,50%	3,80%	6,50%	4,00%	0,70%	3,60%	1,80%	2,00%
Galliford Try	4,70%	3,90%	3,90%	4,20%	7,20%	6,90%	7,20%	7,10%
Greene King	12,90%	24,10%	23,70%	19,60%	14,80%	15,30%	17,90%	16,00%
Genus	5,60%	1,40%	4,50%	3,30%	4,10%	5,00%	7,30%	5,50%
The Go-Ahead Group	43,30%	48,40%	46,60%	46,10%	4,60%	4,40%	5,40%	4,80%
Grainger	3,30%	4,70%	9,50%	5,30%	12,00%	11,60%	16,60%	13,40%
Hargreaves Services	0,10%	11,00%	9,40%	2,10%	1,30%	2,60%	3,00%	2,30%
Haynes Publishing Group	3,80%	2,70%	2,00%	2,70%	12,40%	12,20%	8,50%	11,00%
Imagination Technologies Group	0,40%	1,50%	0,20%	0,50%	0,00%	0,00%	0,00%	0,00%
Imperial Tobacco Group	6,80%	9,10%	7,80%	7,90%	14,00%	14,40%	15,10%	14,50%
ISG	39,20%	4,00%	16,30%	14,80%	3,20%	4,10%	2,90%	3,40%
J D Wetherspoon	71,00%	66,10%	73,30%	70,20%	10,10%	9,80%	11,20%	10,40%
James Halstead	0,00%	1,00%	0,80%	0,00%	0,10%	0,10%	0,10%	0,10%
Kaba Holding	1,40%	1,60%	2,00%	1,60%	1,50%	1,80%	1,70%	1,70%
Kier Group	17,70%	20,00%	27,00%	21,30%	8,90%	6,00%	7,90%	7,60%
KWS Saat	1,80%	1,60%	1,50%	1,60%	1,30%	2,10%	2,40%	1,90%
Lok'N Store Group	16,90%	13,30%	14,50%	14,90%	25,10%	20,30%	25,00%	23,40%
Mcbride	38,60%	27,50%	26,00%	30,40%	12,70%	9,40%	5,00%	9,10%
A & J Mucklow Group	3,30%	10,50%	12,30%	7,60%	3,60%	4,00%	7,20%	4,90%
MS International	5,70%	5,50%	1,00%	3,20%	2,60%	0,30%	0,00%	1,00%


Murgitroyd Group	1,80%	2,20%	3,60%	2,40%	0,30%	0,80%	1,70%	0,90%
Netcall	1,70%	2,70%	2,30%	2,20%	2,90%	5,10%	8,50%	5,50%
Northgate	5,00%	8,00%	13,30%	8,20%	8,30%	8,80%	6,70%	7,90%
NWF Group	29,50%	35,70%	37,80%	34,30%	0,40%	0,40%	0,40%	0,40%
Newmark Security	4,80%	5,60%	11,80%	6,80%	5,30%	7,20%	20,90%	11,10%
Pan African Resources	100,00%	1,20%	0,30%	99,90%	3,80%	4,70%	0,40%	3,00%
Photo - ME International	11,40%	1,10%	6,10%	4,40%	1,10%	3,90%	4,70%	3,30%
Plexus Holdings	68,60%	2,20%	2,70%	10,00%	0,00%	0,00%	2,10%	0,70%
Pure Wafer	3,10%	4,00%	20,20%	6,50%	3,10%	3,70%	80,40%	29,10%
PZ Cussons	2,20%	2,30%	16,40%	4,50%	1,20%	1,40%	1,40%	1,30%
Ricardo	3,50%	3,60%	3,90%	3,60%	1,90%	1,60%	1,90%	1,80%
Redrow	0,80%	0,80%	0,70%	0,80%	3,40%	5,00%	4,90%	4,40%
Regeneris	0,20%	15,10%	10,60%	3,50%	9,10%	4,30%	3,10%	5,50%
Pernod Ricard	1,60%	1,90%	2,00%	1,80%	12,60%	12,80%	17,80%	14,40%
Vilmorin & CIE	3,60%	3,00%	3,50%	3,40%	14,90%	13,50%	13,30%	13,90%
Rnb Retail And Brands	39,20%	47,20%	27,80%	37,70%	100,00%	100,00%	99,90%	100,00%
The Rank Group	28,10%	10,30%	1,30%	7,70%	11,90%	16,60%	1,30%	10,00%
Renishaw	0,10%	0,20%	0,30%	0,20%	0,00%	0,00%	0,00%	0,00%
Sectra	1,10%	1,30%	0,10%	0,50%	0,20%	0,20%	0,00%	0,10%
Stagecoach Group	48,90%	19,90%	19,70%	27,90%	7,20%	9,00%	8,40%	8,20%
The Sage Group	13,30%	12,80%	5,10%	9,70%	4,70%	3,20%	3,50%	3,80%
DS Smith	10,20%	11,00%	3,00%	7,10%	9,30%	16,60%	12,60%	12,80%
WH Smith	27,00%	9,50%	1,40%	4,30%	0,20%	0,30%	0,40%	0,30%
Sinclair Is Pharma	14,40%	4,00%	3,40%	5,90%	42,10%	21,30%	25,00%	29,50%
Swallowfield	22,40%	27,30%	20,50%	23,30%	7,00%	8,10%	6,00%	7,10%
Treant	5,00%	5,00%	5,60%	5,20%	1,10%	1,30%	1,80%	1,40%
Tonnellerie Francois Freres	0,90%	1,00%	1,10%	1,00%	2,80%	5,10%	7,20%	5,00%
ThyssenKrupp	13,10%	15,90%	13,70%	14,20%	19,10%	23,10%	27,40%	23,20%
Tristel	3,90%	2,60%	1,90%	2,70%	4,00%	1,00%	0,30%	1,80%
Wolseley	2,10%	2,20%	2,10%	2,20%	1,10%	1,70%	2,80%	1,90%
Zodiac Aerospace	1,50%	1,30%	1,60%	1,40%	3,30%	3,80%	5,70%	4,20%
Zytronic	0,20%	2,20%	2,10%	1,00%	1,00%	0,00%	0,50%	0,50%
CEZ	3,00%	2,40%	2,70%	2,70%	39,70%	27,90%	28,80%	32,10%
Unipetrol	48,90%	3,40%	3,40%	9,50%	38,60%	27,60%	29,20%	31,80%
Philipp morris	54,40%	3,90%	2,00%	9,00%	40,00%	20,50%	17,20%	25,90%
Pegas	75,20%	9,20%	7,00%	22,20%	21,20%	32,20%	27,50%	26,90%

Tab. 49 Hodnoty účetních modelů s vyznačením jejich pozice v rámci souboru: nadprůměrné (červeně) a podprůměrné hodnoty (zleva od r. 2011 do r. 2014)


Společnost	Alt. m.	Alt. m.	Alt. m.	Alt. m.	Ohl. m.	Ohl. m.	Ohl. m.	Ohl. m.
Associated British Foods	4,99	4,42	3,73	2,29	-5,19	-5	-4,82	-5
Allergy Therapeutics	-1,43	-1,78	-0,57	-3,3	-2,27	-1,99	-2,12	-2,13
Ashtead Group	2,82	2,21	2,04	1,2	-1,98	-1,78	-1,61	-1,79
Anite	4,37	4,49	3,7	1,54	-3,08	-2,98	-3,37	-3,14
Mastrad	1,35	1,61	2,61	1,81	0,67	-1,06	-1,54	-0,64
The Alumasc Group	2,72	2,58	2,45	2,18	-0,69	-0,87	-0,64	-0,73
Avingtrans	2,67	2,21	2,23	1,71	-2,54	-2,38	-2,18	-2,37
Avon Rubber	61,29	72,92	83,41	71,07	-1,92	-1,46	-1,9	-1,76
Barratt Developments	3,07	2,4	2,16	1,68	-5,8	-5,33	-5,39	-5,5
The Berkeley Group Holdings	4,1	3,95	3,66	2,61	-3,48	-4,89	-4,64	-4,34
Bastide LE Confort Medical	2,58	2,71	2,95	1,95	-1,28	-1,46	-1,56	-1,43
Britvic	2,77	2,54	2,37	1,62	-0,61	-0,11	-0,12	-0,28
Bellway	4,46	4,44	3,71	2,57	-6,02	-6,19	-6,13	-6,11
Societe Centrale	0,77	0,85	0,99	0,27	0,68	-0,62	-1,21	-0,38
The Conygar Investment Company	1,72	1,62	0,74	0,52	-3,85	-3,89	-3,56	-3,77
Clas Ohlson	14,21	13,59	14,45	11,24	-3,67	-3,65	-3,79	-3,7
Compass Group	3,37	3,32	2,96	1,78	-2	-2,61	-2,92	-2,51
Carpetright	3,32	3,27	3,55	1,83	0,04	0,05	-0,21	-0,04
Sales force	62,67	48,99	35,28	13,15	-0,45	-0,24	0,21	-0,16
Consort Medical	6,66	5,57	2,86	1,87	-4,75	-4,05	-2,6	-3,8
CVS Group	4,17	3,89	3,67	2,77	-0,4	-0,33	-0,1	-0,28
Diageo	3,61	3,22	2,66	1,36	-3,83	-3,76	-3,6	-3,73
Digital Bros	3	2,63	3,44	1,79	-1,41	-1,3	-1,5	-1,41
Dunelm Group	4,38	9,62	7,4	4,03	-5,19	-5,2	-5,28	-5,23
Dechra Pharmaceuticals	5,53	2,2	2,29	2,1	-4,09	-2,36	-2,18	-2,88
Diploma	10,07	9,46	6,25	2,84	-4,96	-4,95	-4,67	-4,86
Enterprise Inns	1,06	1,06	0,95	0,44	-1,48	-1,45	-1,53	-1,49
Eutelsat Communications	1,42	1,94	2,42	0,79	-2,58	-2,92	-2,81	-2,77
Exel Industries	2,4	2,38	2,92	1,98	-2,65	-2,72	-3,37	-2,91
Easyjet	2,95	2,33	1,75	1,36	-3,39	-3,3	-3,01	-3,23
Fenner	2,61	2,83	2,8	1,72	-2,81	-2,88	-2,82	-2,84
Finsbury Food Group	2,89	2,9	2,41	2,07	-2,43	-2,13	-0,98	-1,85
Future	-2,07	0,57	0,4	-0,79	-0,08	-1,87	-1,13	-1,03
Goldplat	2,55	4,31	3,37	2	-3,31	-2,6	-5,3	-3,74

Goodwin	4,92	3,3	3,98	2,37	-3,67	-3,23	-2,67	-3,19
Galliford Try	2,55	2,61	2,56	2,27	-3,01	-3,19	-3,22	-3,14
Greene King	1,75	1,71	1,53	0,92	-1,91	-1,15	-1,17	-1,41
Genus	3,14	2,94	2,53	1,39	-2,83	-4,26	-3,05	-3,38
The Go-Ahead Group	3,04	3,07	2,86	2,63	-0,27	-0,06	-0,14	-0,16
Grainger	2	2,03	1,61	1,02	-3,36	-3,01	-2,26	-2,88
Hargreaves Services	4,33	3,63	3,49	2,93	-7,18	-2,09	-2,27	-3,84
Haynes Publishing Group	1,96	1,98	2,38	2,18	-3,23	-3,58	-3,9	-3,57
Imagination Technologies Group	8,23	8,36	20,78	1,28	-5,58	-4,19	-6,14	-5,3
Imperial Tobacco Group	1,82	1,79	1,73	0,94	-2,61	-2,3	-2,47	-2,46
ISG	3,4	3,16	3,52	3,27	-0,44	-3,17	-1,64	-1,75
J D Wetherspoon	2,18	2,22	2,07	1,36	0,9	0,67	1,01	0,86
James Halstead	7,24	7,38	6,84	3,15	-113,2	-4,55	-4,83	-40,87
Kaba Holding	4,19	4	4,04	1,92	-4,25	-4,15	-3,87	-4,09
Kier Group	2,33	2,75	2,46	2,41	-1,54	-1,39	-0,99	-1,31
KWS Saat	4,32	3,87	3,7	2,58	-3,97	-4,14	-4,22	-4,11
Lok'N Store Group	1,1	1,37	1,1	0,42	-1,59	-1,87	-1,77	-1,75
Mcbride	1,93	2,26	2,94	2,22	-0,46	-0,97	-1,05	-0,83
A & J Mucklow Group	3,3	3,19	2,56	0,94	-3,39	-2,14	-1,97	-2,5
MS International	3,62	5,67	30,24	12,51	-2,8	-2,85	-4,58	-3,41
Murgitroyd Group	5,76	4,85	4,06	2,35	-4,01	-3,8	-3,3	-3,7
Netcall	3,5	2,92	2,37	1,26	-4,08	-3,59	-3,75	-3,81
Northgate	2,4	2,34	2,64	1,28	-2,94	-2,45	-1,88	-2,42
NWF Group	5,57	5,55	5,57	4,8	-0,87	-0,59	-0,5	-0,65
Newmark Security	2,89	2,55	1,33	1,68	-2,99	-2,83	-2,02	-2,61
Pan African Resources	3,24	3	5,62	2,02	31,54	-4,45	-5,85	7,08
Photo - ME International	4,46	3,2	3,01	1,8	-2,05	-4,47	-2,73	-3,08
Plexus Holdings	11,13	8,12	3,83	1,29	0,78	-3,79	-3,57	-2,2
Pure Wafer	3,44	3,27	-1,41	0,39	-3,46	-3,18	-1,38	-2,67
PZ Cussons	4,4	4,22	4,28	2,18	-3,8	-3,77	-1,63	-3,07
Ricardo	3,97	4,1	3,92	2,36	-3,33	-3,29	-3,21	-3,28
Redrow	3,35	2,95	2,97	2,18	-4,77	-4,8	-5,02	-4,87
Regeneris	2,3	3,1	3,45	2,44	-6,1	-1,73	-2,13	-3,32
Pernod Ricard	1,94	1,92	1,53	0,78	-4,13	-3,94	-3,89	-3,98
Vilmorin & CIE	1,74	1,86	1,88	1,05	-3,3	-3,48	-3,3	-3,36
Rnb Retail And Brands	-24,8	-17,48	-7,25	-17,39	-0,44	-0,11	-0,95	-0,5
The Rank Group	2	1,61	4,3	1,64	-0,94	-2,16	-4,35	-2,48


Renishaw	8,37	8,24	8,04	3,03	-6,96	-6,04	-5,76	-6,26
Sectra	6,47	6,22	8,16	5,23	-4,46	-4,36	-7,27	-5,36
Stagecoach Group	2,56	2,32	2,39	1,44	-0,04	-1,39	-1,41	-0,95
The Sage Group	3,01	3,42	3,32	1,36	-1,87	-1,92	-2,92	-2,24
DS Smith	2,28	1,62	1,94	1,87	-2,17	-2,09	-3,47	-2,58
WH Smith	6,13	5,77	5,5	4,42	-0,99	-2,25	-3,21	-3,46
Sinclair Is Pharma	0,32	1,31	1,1	-0,27	-1,78	-3,18	-3,34	-2,77
Swallowfield	2,58	2,43	2,75	2,41	-1,24	-0,98	-1,36	-1,19
Treant	4,49	4,3	3,98	3,22	-2,95	-2,94	-2,82	-2,9
Tonnellerie Francois Freres	3,56	2,92	2,56	1,77	-4,75	-4,56	-4,51	-4,6
ThyssenKrupp	1,45	1,2	0,98	1,28	-1,89	-1,67	-1,84	-1,8
Tristel	3,19	4,58	5,68	1,19	-3,21	-3,63	-3,95	-3,6
Wolseley	4,46	4,05	3,55	2,71	-3,82	-3,78	-3,82	-3,81
Zodiac Aerospace	3,38	3,25	2,81	1,72	-4,21	-4,36	-4,09	-4,22
Zytronic	4,59	8,24	5,2	2,31	-6	-3,81	-3,86	-4,56
CEZ	0,94	1,53	1,54	0,72	-3,48	-3,69	-3,6	-3,59
Unipetrol	2,85	2,9	2,76	1,43	-0,05	-3,36	-3,35	-2,25
Philipp morris	1,34	2,36	2,87	1,32	0,18	-3,21	-3,91	-2,32
Pegas	2,29	1,63	1,73	1,35	1,11	-2,29	-2,59	-1,26




Obr. 49 Stanovení počtu komponent pro dendrogram za data za rok 2011 (8 komponent)



Obr. 50 Stanovení počtu komponent pro dendrogram za data za rok 2012 (10 komponent)



Obr. 51 Stanovení počtu komponent pro dendrogram za data za rok 2013 (10 komponent)



Obr. 52 Stanovení počtu komponent pro dendrogram za data za rok 2014 (10 komponent)

Tab. 50 Značky společností a obor podnikání

Společnost	Zkratka CP	Odvětví	Společnost	Zkratka CP	Odvětví
Associated British Foods PLC	abf	G.	J D Wetherspoon PLC	jdw	I.
Allergy Therapeutics PLC	agy	C.	James Halstead PLC	jhd	C.
Ashtead Group Public Limited Company	aht	N.	Kaba Holding AG	kabn	C.
Anite PLC	aie	C.	Kier Group PLC	kie	F.
Mastrad	msi	C.	KWS Saat AG	kws	A.
The Alumasc Group PLC	almas	G.	Lok'N Store Group PLC	lok	S.
Avingtrans PLC	avg	C.	Mcbride PLC	mcb	C.
Avon Rubber P.L.C.	avon	C.	A & J Mucklow Group PLC	mklw	L.
Barratt Developments P L C	bdev	F.	MS International PLC	msi	C.
The Berkeley Group Holdings PLC	bkg	F.	Murgitroyd Group PLC	mur	L.
Bastide LE Confort Medical	bhc	G.	Northgate PLC	ntg	N.
Britvic PLC	bvic	C.	NWF Group PLC	nwf	C.
Bellway P.L.C.	bwy	F.	Newmark Security PLC	nwt	N.
Societe Centrale DES Bois ET DES Scieries	cbsm	L.	Pan African Resources PLC	paf	B.
The Conygar Investment Company PLC	cic	L.	Photo-ME International P L C	phtml	S.
Clas Ohlson Aktiebolag	clas	G.	Plexus Holdings PLC	pos	C.
Compass Group PLC	cpg	M.	Pure Wafer PLC	pur	C.
Carpetright PLC	cpr	G.	PZ Cussons PLC	pzc	C.
Consort Medical PLC	csrt	C.	Ricardo PLC	rcdo	M.
CVS Group PLC	cvsg	M.	Redrow PLC	rdw	F.
Diageo PLC	dge	C.	Regeneris PLC	rgs	J.
Digital Bros S.P.A.	dib	G.	Pernod Ricard	ri	M.
Dunelm Group PLC	dnlm	G.	Vilmorin & CIE	rin	M.
Dechra Pharmaceuticals PLC	dph	C.	Rnb Retail And Brands AB (Publ)	rnbs	M.
Diploma PLC	dplm	G.	The Rank Group PLC	rnk	R.
Enterprise Inns PLC	eti	I.	Renishaw P L C	rsw	C.
Eutelsat Communications	etl	J.	Sectra Aktiebolag	sect	M.
Exel Industries	exe	C.	Stagecoach Group PLC	sgc	H.
Easyjet PLC	ezj	H.	The Sage Group Plc.	sge	M.
Fenner PLC	fenr	C.	DS Smith PLC	smds	G.
Finsbury Food Group PLC	fif	C.	WH Smith PLC	smwh	G.
Future PLC	futr	J.	Sinclair Is Pharma PLC	sph	C.
Goldplat PLC	gdp	B.	Swallowfield PLC	swl	C.
Goodwin PLC	gdwn	C.	Treatt PLC	tet	G.
Galliford Try PLC	gfrd	F.	Tonnellerie Francois Freres	tff	C.
Greene King PLC	gnk	I.	ThyssenKrupp AG	tka	M.

Genus PLC	gns	M.	Tristel PLC	tstl	E.
The Go-Ahead Group PLC	gog	H.	Wolseley PLC	wos	G.
Grainger PLC	gri	F.	Zodiac Aerospace	zc	M.
Hargreaves Services PLC	hsp	H.	Zytronic PLC	zyt	C.
Haynes Publishing Group Public Limited Company	hyns	J.	CEZ	CEZ	C.
Imagination Technologies Group PLC	img	J.	Unipetrol	Unipetrol	C.
Imperial Tobacco Group PLC	imt	C.	Philipp morris	Philipp morris	C.
ISG PLC	isg	F.	Pegas	Pegas	C.

Pozn.: Význam značek odvětví: G. Velkoobchod a maloobchod, oprava motorových vozidel; C. Výroba; N. Administrativa a podpůrné služby; F. Konstrukční činnosti; L. Realitní služby a development; M. Profesionální vědní a technické služby; J. Informační služby a komunikace; B. Těžba a zpracování surovin; H. Přeprava a skladování; S. Ostatní služby; I. Ubytování a pohostinství; R. Umění, zábava a rekreace.