

Predikce tvorby ekonomické přidané hodnoty

Diplomová práce

Vedoucí práce:

doc. Mgr. David Hampel, Ph.D.

Bc. Radek Mitáček

Brno 2016

Chci na tomto místě poděkovat svému vedoucímu doc. Mgr. Davidu Hampelovi, Ph.D. za cenné rady a trpělivost, které přispěly ke zdárnému dokončení této práce.

Čestné prohlášení

Prohlašuji, že jsem tuto práci: Predikce tvorby ekonomické přidané hodnoty vypracoval/a samostatně a veškeré použité prameny a informace jsou uvedeny 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 o tom, 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 20. května 2016

Abstract

Mitáček, R., Prediction of creation of Economic Value Added, Diploma Thesis. Brno: MENDELU in Brno 2016.

The purpose of the thesis is to research possibilities related to prediction of the economic value added, so called EVA¹ for the companies operating at Czech market. The outcome consists of set of models which may be used for a considerably accurate estimate whether an investigated company is going to produce positive value for its owners and creditors or not. Multiple discriminant analysis is used. The models cover all the sectors in the economy according to NACE categorization but finance and insurance industries and sectors managed by government and this breadth enables high level of usefulness of the outputs.

Keywords

Financial Analysis, Economic Value Added, Factor Analysis, Multiple Discriminant Analysis.

Abstrakt

Mitáček, R., Predikce tvorby ekonomické přidané hodnoty, Diplomová práce. Brno: MENDELU v Brně 2016.

Práce se zabývá možnostmi predikce tvorby ekonomické přidané hodnoty, tzv. EVA u společností působících na českém trhu. Výsledkem je sada matematických modelů, které mohou být využity k relativně přesnému odhadu, zdali námi zkoumaná společnost bude vytvářet hodnotu pro své majitele a věřitele, či nikoliv. Ke tvorbě modelů byla využita vícerozměrná diskriminační analýza. Modely pokrývají téměř všechna odvětví hospodářství dle kategorizace NACE s výjimkou sekce peněžnictví a pojišťovnictví a státní sféry, což umožňuje širokou využitelnost výsledků práce.

Klíčová slova

Finanční analýza, Ekonomická přidaná hodnota, Faktorová analýza, Vícerozměrná diskriminační analýza.

¹ EVA® je ochrannou známkou registrovanou společností Stern Value Management (dříve Stern Stewart & Co).

Obsah

| | | |
|----------|--|-----------|
| 1 | Úvod a cíl práce | 12 |
| 1.1 | Úvod..... | 12 |
| 1.2 | Cíl práce..... | 12 |
| 2 | Teoretická východiska | 14 |
| 2.1 | Finanční analýza | 14 |
| 2.2 | Poměrové ukazatele | 16 |
| 2.3 | Ekonomická přidaná hodnota | 20 |
| 2.4 | Makroekonomické prostředí | 22 |
| 2.5 | Diskriminační a faktorová analýza | 23 |
| 3 | Praktická část | 27 |
| 3.1 | Metodika | 27 |
| 3.2 | Data | 28 |
| 3.2.1 | Popis základních dat a nezávislých proměnných..... | 28 |
| 3.2.2 | Popis modelované proměnné..... | 35 |
| 3.3 | Testování předpokladů | 36 |
| 3.3.1 | Vícerozměrné normální rozdělení..... | 36 |
| 3.3.2 | Shodné kovarianční matice | 37 |
| 3.3.3 | Nezávislost průměrů a směrodatných odchylek proměnných | 38 |
| 3.4 | Výstavba a testování modelů | 38 |
| 3.5 | Výsledky | 42 |
| 3.5.1 | Všeobecný model..... | 42 |
| 3.5.2 | Oborové modely..... | 53 |
| 4 | Diskuze | 58 |
| 5 | Závěr | 62 |
| 6 | Literatura | 63 |
| A | Seznam zkratk rozvahových a výsledkových položek | 67 |

| | | |
|----------|--|-----------|
| B | Seznam všech poměrových ukazatelů | 68 |
| C | Seznam všech makroekonomických ukazatelů | 73 |
| D | Klasifikační funkce pro oborový model sekce A: Zemědělství, lesnictví a rybářství | 74 |

Seznam obrázků

| | | |
|--------|---|----|
| Obr. 1 | Úspěšnost klasifikace případů IN05 Zdroj: Neumaierová, 2005. | 22 |
| Obr. 2 | Sutinový graf pro první skupinu proměnných | 31 |
| Obr. 3 | Q-Q graf, EVA_0 | 37 |
| Obr. 4 | Krabicový graf kategorizovaný: ROE – Rentabilita vlastního kapitálu % P/L for Period [=Net income]/Shareholders Funds | 47 |
| Obr. 5 | Krabicový graf kategorizovaný: CZK/EUR průměr 2005-2013 | 48 |
| Obr. 6 | Krabicový graf kategorizovaný: Capital Turnover Current Assets/Total Assets | 48 |
| Obr. 7 | Krabicový graf kategorizovaný: Rentabilita tržeb % (Operating P/L [=EBIT/Operating revenue (Turnover)]) | 48 |
| Obr. 8 | Krabicový graf kategorizovaný: Debt Equity ratio % (Non-Current Liabilities+Current Liabilities)/Shareholders Funds | 49 |
| Obr. 9 | Úspěšnost klasifikace případů IN05 Zdroj: Neumaierová, 2005. | 60 |

Seznam tabulek

| | | |
|---------|--|----|
| Tab. 1 | Ukazatele rentability | 17 |
| Tab. 2 | Ukazatele aktivity | 17 |
| Tab. 3 | Ukazatele zadluženosti | 18 |
| Tab. 4 | Ukazatele likvidity | 18 |
| Tab. 5 | Ukazatele produktivity práce | 19 |
| Tab. 6 | Ukazatele kapitálového trhu | 19 |
| Tab. 7 | Posloupnost filtrování dat v databázi Amadeus | 28 |
| Tab. 8 | Rozdělení hospodářství dle NACE: modelované skupiny | 29 |
| Tab. 9 | Úpravy o pozorování s extrémními hodnotami | 30 |
| Tab. 10 | První skupina proměnných pro faktorovou analýzu | 31 |
| Tab. 11 | Tabulka vlastních čísel pro první skupinu proměnných | 32 |
| Tab. 12 | Faktorové zátěže pro první skupinu proměnných (Varimax rotace) | 32 |
| Tab. 13 | Skupiny, na něž byla aplikována faktorová analýza | 33 |
| Tab. 14 | Makroekonomické proměnné vstupující do modelů | 34 |
| Tab. 15 | Tabulka četností EVA_0 pro záporná pozorování | 37 |
| Tab. 16 | Výsledek testování síly modelu. | 38 |
| Tab. 17 | Prověření korelace mezi průměry a rozptyly | 38 |
| Tab. 18 | Počet pozorování u odvětví určený k tvorbě a testování modelů | 40 |
| Tab. 19 | Rozložení oborů v národním hospodářství a ve zkoumaných datech | 41 |
| Tab. 20 | Dialog výsledků diskriminační analýzy po 5 krocích | 43 |

| | | |
|----------------|---|-----------|
| Tab. 21 | Test významnosti modelu | 43 |
| Tab. 22 | Prosté koeficienty, celkový model s makroekonomickými proměnnými | 44 |
| Tab. 23 | Skupinové centroidy, celkový model s makroekonomickými proměnnými | 44 |
| Tab. 24 | Párové t-testy o rovnosti průměrů | 46 |
| Tab. 25 | Klasifikační funkce: grupovací: model s makroekonomickými proměnnými | 49 |
| Tab. 26 | Hodnoty prvního pozorování v datech | 49 |
| Tab. 27 | Klasifikační matice, celkový model s makroekonomickými proměnnými | 50 |
| Tab. 28 | Testování predikce, celkový model s makroekonomickými proměnnými | 50 |
| Tab. 29 | Prosté koeficienty, celkový model bez makroekonomických proměnných | 51 |
| Tab. 30 | Skupinové centroidy, celkový model bez makroekonomických proměnných | 52 |
| Tab. 31 | Klasifikační matice, celkový model bez makroekonomických proměnných | 52 |
| Tab. 32 | Klasifikační matice k predikci, celkový model bez makroekonomických proměnných | 52 |
| Tab. 33 | Prosté koeficienty, A, Zemědělství, lesnictví a rybářství s makroekonomickými proměnnými | 53 |
| Tab. 34 | Skupinové centroidy, A, Zemědělství, lesnictví a rybářství s makroekonomickými proměnnými | 54 |
| Tab. 35 | Prosté koeficienty, A, Zemědělství, lesnictví a rybářství bez makroekonomických proměnných | 54 |
| Tab. 36 | Predikce, Sekce A: Zemědělství, lesnictví a rybářství bez makroekonomických proměnných | 55 |
| Tab. 37 | Tabulka četností objevení se proměnných ve 13 oborových modelech | 55 |

| | | |
|----------------|---|-----------|
| Tab. 38 | Klasifikační matice: průměrné hodnoty predikce: 13 oborových modelů | 57 |
| Tab. 39 | Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 1. část | 68 |
| Tab. 40 | Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 2. část | 69 |
| Tab. 41 | Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 3. část | 70 |
| Tab. 42 | Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 4. část | 71 |
| Tab. 43 | Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 5. část | 72 |
| Tab. 44 | Seznam makroekonomických proměnných, červené se objevily při konečném modelování | 73 |
| Tab. 45 | Klasifikační funkce grupovací pro obor Zemědělství, lesnictví a rybářství bez makroekonomických proměnných | 74 |

1 Úvod a cíl práce

1.1 Úvod

V posledních desetiletích se výrazně proměnil primární cíl existence většiny podniků. Společnosti již nevyznávají klasický model maximalizace tržeb, tržního podílu či zisku, ale zaměřují se na růst své hodnoty. Důvodem pro to je rozvoj akciových trhů a mimoburzovního trhu s podniky, zejména v anglosaských zemích. Podnikatelé často nebudují firmu jako celoživotní dílo, ale nechají ji vyrůst a v určité fázi ji prodají či s ní vstoupí na burzu. Jako příklady bychom mohli uvést koupi populární aplikace WhatsApp Facebookem v hodnotě 22 miliard dolarů (Reuters, 2014), či vstup společnosti Tesla Motors na Newyorskou burzu v roce 2010 (Tesla, 2010).

Dlužno dodat, že nejtypičtějším odvětvím, kde k tzv. exitům dochází, jsou v současné době technologické a IT společnosti. Zakladatelé takovýchto firem většinou přicházejí s nápadem, do nějž pak investoři vkládají své know-how týkající se provozu, kontakty a především peníze.

Cílem investorů je tyto peníze zhodnotit a to prostřednictvím vstupu na burzu či prodejem společnosti většímu hráči na trhu, který tak může obnovovat své inovační kapacity. S ohledem na vysokou rizikovost start-up projektů je požadována vysoká návratnost investice a firmy bývají k IPO (Initial Public Offering) neboli veřejné nabídce akcií silně tlačeny. V České republice se nenachází vysoce rozvinutý akciový trh, což je dáno především nízkým počtem skutečně atraktivních firem, které se na Pražské burze cenných papírů či v RM systému obchodují. Na druhou stranu zde roste poměrně široká škála slibných start-upů. Za zmínku v této chvíli stojí české společnosti, jako jsou Socialbakers zabývající se analýzou dat ze sociálních sítí či raketově rostoucí Skypicker, který působí na poli retailu letenek. Téma hodnoty podniku a její tvorby tudíž považuji z pohledu podnikání v České republice za více aktuální než kdy v minulosti i s ohledem na historický vývoj hospodářství a proto se jím budeme v této práci zabývat.

1.2 Cíl práce

Cílem práce je zaměřit se na otázku růstu hodnoty podniku v čase a pokusit se tento růst s pomocí statistických metod zachytit, kvantifikovat a případně predikovat. K vlastní analýze budou využita data z databáze Amadeus obsahující informace o finančních i nefinančních ukazatelích společností v celé Evropě v časovém rámci několik let. Makroekonomická data budou získána ze stránek Českého statistického úřadu. Tvorba hodnoty podniku, dále již jen EVA (Economic Value Added), neboli ekonomická přidaná hodnota, bude analyzována v rámci českého ekonomického prostoru. Nejdříve v rámci obecné roviny bez konkrétní návaznosti na odvětví, poté již v detailu s ohledem na jednotlivá odvětví. Výsledkem budou matematické modely schopné poskytovat spolehlivé informace o budoucím vývoji podniků. Přestože zdaleka nevyčerpáme všechny možnosti, v rámci práce se pokusíme ma-

ximalizovat predikční schopnost modelu. Z čistě pragmatického hlediska spolehlivý odhad o budoucím vývoji podniku může být využit jak vlastníky podniku, tak především potencionálními investory, finančními analytiky zabývajícími se vývojem společností, státní správou či finančními institucemi jako prostředek k určení vývoje ziskovosti a tím i např. kredibility podniku.

2 Teoretická východiska

V rámci teoretické části budou vytyčeny základní poznatky vztahující se k teorii financí podniku, dále bude blíže rozebrána EVA a makroekonomické prostředí podniku. V poslední části se budeme věnovat metodám využitým k vytvoření modelů.

2.1 Finanční analýza

Každá společnost bez ohledu na to, v jakém odvětví působí, je nucena racionálně řídit svoji finanční stránku. A to tak, aby neohrozila svoji existenci nebo ještě lépe, byla schopna investovat a růst. U velkých společností má toto za úkol oddělení financí, většinou rozdělené do menších sekcí, jež se věnují rozdílným problematikám, jako je účetnictví, analýzy a plánování a podobně. U menších firem se většinou musí skloubit více rolí v několika málo lidech, což odpovídá složitosti a objemu problémů a příležitostí, které mohou vyvstat. V čase 25 let po sametové revoluci se v České republice poměrně úspěšně rozvíjí tržní hospodářství, k 31. 3. 2016 bylo registrováno téměř 2 777 282 ekonomických subjektů (ČSÚ, 2016b). V zájmu státu, akademiků i dalších stakeholderů od investorů po zaměstnance je, aby tyto subjekty vytvářely hodnoty prospěšné společnosti a těm, kdo se o ně zasadili, přinášely pravidelně mzdy, případně dividendy či úrok. Nejen z tohoto důvodu došlo ke zkoumání finanční stránky podniků a k vývoji teorie, která formalizuje metody průzkumu a jejich vhodné využití. Souhrnně se tyto metody označují jako finanční analýza podniku.

Finanční analýza je tedy široká škála postupů umožňující získat rozšířené poznatky o dosavadním vývoji hospodaření podniku. Dlužno dodat, že nejde pouze o samotné peníze, ale o kompletní toky zboží, pohledávek, závazků a dalších aktiv či pasiv v podniku vyjádřené v peněžních jednotkách. Základními uživateli finanční analýzy dle Kislingerové (2010) jsou:

- Investoři
 - Skupina zahrnuje širokou škálu subjektů od individuálních investorů po s miliardami hospodařící organizace. Mezi investory zde budeme řadit i zakladatele podniku. Typickým účelem finanční analýzy je porovnávání investičních příležitostí. Zkoumání klasického trojúhelníku likvidita-výnos-riziko. Hojně využíváno u akciových společností kótovaných na burze za účelem posouzení budoucího nákupu/prodeje cenných papírů.
- Banky a ostatní věřitelé
 - Motivem je určení bonity klienta, tzn., zdali je firma v případě poskytnutí úvěru schopna splácet. Pro věřitele je zajímavá velikost dosavadního dluhu a potenciální cashflow zkoumané společnosti. Existuje široká literatura zabývající se tvorbou skoringových modelů,

kteří umožňují rozlišit mezi bonitními a bankrotními společnostmi, zřejmě nejznámějším je model Z-skóre (Altman, 1968).

- Stát a jeho orgány
 - V zájmu veřejné správy je stabilita společností z důvodu zachování zaměstnanosti a výběr daní. Dobrým aktuálním příkladem, kdy se stát musí intenzivně zajímat o vývoj podniku je úpadek společnosti OKD, která je významným zaměstnavatelem v regionu s téměř 10 000 zaměstnanci, jejíž dluhy dosahují výše 17 mld. Kč a aktiva pouhých 7 mld. Kč.
- Obchodní partneři
 - Podmínkou stability a rozvoje každé společnosti je stálost obchodních partnerů v celém dodavatelsko-odběratelském řetězci. U odběratelů je zájem z jasného důvodu platby pohledávek, u dodavatelů jde o zajištění jistoty dodávek materiálu, zboží, případně jiných vstupů.
- Management podniku
 - Zřejmě nejčastější uživatelé finanční analýzy. Ze všech uživatelů mají nejlepší přístup k informacím zahrnující nejen finanční, ale i nákladové účetnictví. Management podniku bývá hodnocen pomocí klíčových ukazatelů výkonu, neboli KPI (Key Performance Indicators), kde výsledek hospodaření a další, dílčí ukazatele bývají jejich součástí. Z pohledu fungování podniku by se dalo řízení financí managementem rozdělit dle horizontu, v jakém se lze rozhodovat. Z krátkodobého hlediska se jedná o řízení pracovního kapitálu, tzn., aby měl podnik prostředky na mzdy, platby dodavatelům apod. a z dlouhodobého o řízení investic a rozvoj podniku.
- Zaměstnanci
 - Jejich motivem je udržení, případně zlepšování mzdových a sociálních podmínek. Ačkoliv by tito stakeholdeři měli bát jedněmi z prvních, kteří se budou o finanční stránku podniku, kde pracují zajímat, nedá se očekávat, že by se to dělo na širší bázi. A to jednoduše z důvodů znalostí problematiky. Těmi totiž obvykle zaměstnanci, nepracující přímo na oddělení financí, nedisponují.

Z pohledu uživatelů je tato práce nejvíce využitelná pro management podniku a investory. Tyto 2 skupiny svá rozhodnutí na rozdíl od ostatních zakládají také v souvislosti s růstem hodnoty podniku v čase.

Vstupními daty do finanční analýzy jsou údaje z účetní závěrky. Jde o informace z klasických výkazů rozvahy, výkazu zisku a ztrát, případně cashflow. Finanční management podniku je díky tomu zcela jasně navázán na účetnictví. Z toho vyplývají 2 typické nevýhody. První z nich je dostupnost informací. Účetní závěrka spojená s reportováním směrem ze společnosti probíhá u společností neobchodovaných na burze jednou ročně, společnosti kótované na burzách pak mohou mít po-

vinnost reportovat o výsledcích častěji např. kvartálně. Rok je poměrně dlouhá doba a ve společnosti se může udát mnoho věcí. Rozvaha ukazuje stav aktiv a pasiv k danému okamžiku. V případě, že ji využíváme k analýze o několik měsíců později, je třeba jisté opatrnosti. Dalším problémem je výše zmíněná závislost na finančním účetnictví. I v rámci platných zákonů lze významně pohybovat s klíčovými ukazateli. Příkladem budiž účtování o dohadných položkách a rezervách, které mohou významně ovlivnit provozní výsledek hospodaření. Pokud možno, dle zkoumané problematiky je pak nutné očistit data o veličiny, které by mohly významně zkreslit skutečný výsledek. V rámci analýzy hodnoty podniku existují doporučené úpravy, více budou rozebrány v části věnující se samotné EVA.

Základními metodami finanční analýzy jsou horizontální a vertikální analýza. Horizontální analýza umožňuje sledovat změny rozvahových a výsledkových veličin v čase v absolutním i relativním vyjádření. Její matematická podoba dle Kislingerové (2008) je

$$D_t = B_i(t) - B_i(t - 1), \quad (1)$$

kde D_t vyjadřuje změnu mezi obdobími a $B_i(t)$ hodnotu bilanční položky v čase t a $B_i(t-1)$ hodnotu bilanční položky v čase $t-1$.

Vertikální analýza se zabývá vztahem rozvahových či výsledkových položek k jejich sumě. U rozvahových položek se většinou jedná o celková aktiva, u výsledkových o tržby či přidanou hodnotu. Formálně se takový vztah dá zapsat jako:

$$P_i = \frac{B_i}{\sum B_i}, \quad (2)$$

kde P_i označuje vztah a B_i zkoumanou i -tou veličinu.

2.2 Poměrové ukazatele

Výše uvedené metody nedovolí příliš zkoumat stav podniku v souvislostech. Rozšířením vertikální analýzy lze hovořit o analýze poměrových ukazatelů. Budeme se jí věnovat detailněji, neboť poměrové ukazatele tvoří hlavní vstup do modelování. V současné době jde zřejmě o v literatuře nejpoblárnější metodu zkoumání financí podniků z důvodů jednoduchosti analýzy a možnosti snadno interpretovat výsledky. Poměrové ukazatele se běžně dělí do několika skupin na základě toho, jaké finanční stránce podniku se věnují. Níže jsou uvedeny skupiny poměrových ukazatelů tak, jak je vidí Kislingerová a Hnilica (2008) a Chen a Shimerda (1981) a jež byly použity v této práci jako základní vstupní data. Význam zkratk v tabulkách lze dohledat v příloze.

- Rentabilita

Zobrazuje efektivitu vložených prostředků, poměřuje výnosy na různých úrovních zisku s vloženým kapitálem či aktivy, pomocí nichž bylo výnosů dosaženo. V Tabulce 1 je základní přehled ukazatelů rentability. Jedná se o jeden ze základních způsobů, na jehož základě se hodnotí výkonnost společnosti.

Tab. 1 Ukazatele rentability

| Poměrový ukazatel | Výpočet |
|---|-------------------------------|
| ROA- rentabilita celkových aktiv | EBIT/AKT |
| Rentabilita tržeb | EBIT/T |
| ROCE – Rentabilita kapitálu | EBIT/(VK + DK) |
| ROE – Rentabilita vlastního kapitálu | ČZ/VK |
| Rentabilita tržeb | ČZ/T |
| Finanční páka | AKT/VK |
| Rentabilita vlastních finančních zdrojů | CF/VK |
| Mzdová náročnost tržeb | Mzdové náklady/Tržby + výkony |

Zdroj: Kislíngrová a Hnilica (2008)

- Aktivita

Měří počet obrátek za rok a dobu obratu aktiv a pasiv. Ukazatele vyjadřují, jak rychle se používaná aktiva „obráť“ v podniku, tzn. jaký je poměr tržeb k použitým aktivům. Doba obratu vyjadřuje, jak průměrně dlouho zkoumaná aktiva/pasiva stráví v podniku. V Tabulce 2 jsou použité ukazatele aktivity.

Tab. 2 Ukazatele aktivity

| Poměrový ukazatel | Výpočet |
|----------------------------------|--------------------|
| Obrat aktiv | T/AKT |
| Doba obratu aktiv | AKT/(T/360) |
| Doba obratu zásob | Zásoby/(T/360) |
| Doba inkasa pohledávek | Pohledávky/(T/360) |
| Doba úhrady krátkodobých závazků | KZ/(T/360) |

Zdroj: Kislíngrová a Hnilica (2008)

- Zadluženost

Ukazuje vztahy mezi vlastním a cizím kapitálem. Financování pomocí cizího kapitálu by se mělo řídit podle určitých pravidel tak, aby nedocházelo k předlužení společnosti a zároveň společnost operovala s přijatelně drahým kapitálem. Zřejmě neznámějším pravidlem je tzv. zlaté pravidlo financování, které udává, že dlouhodobý majetek by měl být financován zdroji s vyšší dobou splatnosti, než je jeho životnost, z čehož vyplývá podmínka financování dlouhodobých aktiv vlastním kapitálem a dlouhodobými úvěry.

Tab. 3 Ukazatele zadluženosti

| Poměrový ukazatel | Výpočet |
|-------------------|-------------------------|
| Debt Ratio I. | CZ/AKT |
| Debt Ratio II. | $(CZ + OP)/AKT$ |
| Úrokové krytí I. | $EBIT/úroky$ |
| Úrokové krytí II. | $(EBIT + odpisy)/úroky$ |

Zdroj: Kislingerová a Hnilica (2008)

- Likvidita

Zobrazuje schopnosti podniku splácet své závazky a reagovat na neočekávané výdaje. Nejvíce vypovídající je rozdílový ukazatel pracovní kapitál spočítaný jako rozdíl oběžných aktiv a krátkodobých dluhů. Ukazuje, s jakou částkou může podnik v daném okamžiku pracovat, aniž by se musel obávat ohrožení jeho solventnosti anebo, v případě záporného pracovního kapitálu, v jaké hodnotě mu chybí oběžná aktiva, aby mohl v daný okamžik splatit své krátkodobé dluhy. Dalšími důležitými ukazateli ve skupině jsou různé typy likvidity zobrazující poměry rozdílně likvidních složek oběžného majetku k dluhům podniku.

Tab. 4 Ukazatele likvidity

| Poměrový ukazatel | Výpočet |
|----------------------------|-------------------|
| Pracovní kapitál | $OAKT - KD$ |
| Pracovní kapitál na aktiva | $(OAKT - KD)/AKT$ |
| Ukazatele kapitalizace | DM/DK |
| Běžná likvidita | $OAKT/KD$ |
| Rychlá likvidita | $(KrP + FM)/KD$ |
| Peněžní likvidita | FM/KD |

Zdroj: Kislingerová a Hnilica (2008)

Pro ukazatele běžná likvidita a pohotová likvidita Kislingerová (2010) doporučuje hodnoty s ohledem na rozdílné podnikové strategie řízení rizika. U běžné likvidity by konzervativně řízená společnost měla mít více než 2,5 násobek krátkodobých dluhů v oběžných aktivech, na druhou stranu agresivně řízená společnost pouze 1,6. Pro rychlou, jinými slovy pohotovou likviditu uvádí jako konzervativní hodnoty vyšší než 1,5 a agresivní hodnoty mezi nižší než 1.

- Produktivita práce

Ukazatele produktivity práce sledují výkonnost podniku ve vztahu k nákladům na zaměstnance. Zde uvedené ukazatele

Tab. 5 Ukazatele produktivity práce

| Poměrový ukazatel | Výpočet |
|--------------------------------------|----------------------------------|
| Osobní náklady k přidané hodnotě | Mzdové náklady/přidaná hodnota |
| Produktivita práce z přidané hodnoty | Přidaná hodnota/počet pracovníků |
| Produktivita práce z tržeb | T/počet pracovníků |
| Průměrná mzda | Mzdové náklady/počet pracovníků |

Zdroj: Kislingerová a Hnilica (2008)

- Výkonnost kapitálového trhu

Poslední literaturou uznávanou skupinou, pro úplnost, jsou ukazatele kapitálového trhu zobrazující, jak vysoce společnosti hodnotí trh. Ukazatele jsou relevantní pouze u akciových společností obchodovaných na burze. Z toho vyplývá, že později nebyly použity v práci, neboť ta se neomezuje pouze na tento typ společností.

Tab. 6 Ukazatele kapitálového trhu

| Poměrový ukazatel | Výpočet |
|--------------------------------|-----------------------------------|
| VK na akcii | VK/počet akcií |
| Účetní zisk na akcii (EPS) | Z/počet akcií |
| Tržní cena akcie | |
| Vyplacená dividenda | |
| Návratnost akcie ze zisku (PE) | Tržní cena akcie/Zisk |
| Market ratio | Tržní cena akcie x počet akcií/VK |
| Dividendový výnos (DY) | Dividenda/tržní cena akcie |
| Výplatní poměr | Dividenda na akcii/EPS |

Zdroj: Kislingerová a Hnilica (2008)

Chen a Shimerda (1981) se ve své práci zabývali využitím poměrových ukazatelů v matematických modelech a redukcí jejich počtu. Shromáždili jich desítky z několika studií a pomocí faktorové analýzy byli schopni odstranit množství ukazatelů poskytujících redundantní informace. Srovnáním 7 studií popsali celkem 7 faktorů, jež nazvali návratnost kapitálu, obrat kapitálu, finanční páka, krátkodobá likvidita, peněžní likvidita, obrat zásob a obrat pohledávek. Jak poznamenávají, využití vysoce korelovaných nezávislých proměnných při vícerozměrné analýze dat vede ke zkreslení vztahů mezi závislou a nezávislými proměnnými.

2.3 Ekonomická přidaná hodnota

Ekonomická přidaná hodnota (EVA) byla významně rozvinuta Joelem Sternem na počátku 90. let. Principem EVA je výpočet tzv. ekonomického zisku, což je rozdíl mezi čistým ziskem z provozní činnosti a náklady na veškerý investovaný kapitál. Viz rovnice

$$EVA = NOPAT - WACC * C, \quad (3)$$

kde NOPAT je Net operating income after taxes (čistý zisk z provozní činnosti po zdanění), WACC jsou weighted average cost of capital (průměrné vážené náklady na kapitál) a C je investovaný kapitál. Veškeré veličiny by měly být spojeny s provozní činností podniku a reálnými výnosy díky tomu získanými. Protože jde o data obvykle získaná z účetnictví, zahrnují v sobě výše uvedené položky části nesouvisící s provozem či jinak ovlivňují skutečný výsledek hospodaření a skutečné využití kapitálu. Dle Mouritsena (1998) konzultantská společnost Stern Value Management navrhuje až 164 úprav, které by měly vést ke zpřesnění výpočtu. Young (1997) nevidí potřebu tolika změn, zdůrazňuje 4 nejdůležitější.

Jsou to úprava o tvorbu a rozpouštění rezerv, náklady na výzkum a vývoj, operativní leasing a goodwill. Pomocí rezerv jsou společnosti schopné významně upravovat výsledek hospodaření. V dobrých časech bývá zvykem rezervy tvořit a ve špatných rozpouštět, což jde tzv. profit smoothing hraničící s ilegality.

Navíc, rezervy nemusejí být správně tvořeny už jen z důvodů komplikovanosti odhadu jejich potřeby. Proto by měl být výsledek hospodaření o tuto položku upraven. Další položkou jsou náklady na výzkum a vývoj. Běžným postupem je účtování o těchto nákladech jako nákladech běžného období, což neodpovídá životnosti výsledků vývoje a uměle snižuje kapitál v daném období a zlepšuje EVA. Lepším postupem by byla kapitalizace do rozvahy a postupné odpisování po dobu životnosti.

Operační leasing je častou formou využití aktiv k podnikání. V rozvaze aktiva využívaná tímto způsobem ale nenajdeme, náklady se účtují přímo do výsledovky. To způsobuje umělé vykazání nižšího kapitálu vynaloženého k získání výnosů. Proto je vhodné zařadit do kapitálu hodnotu budoucích leasingových plateb diskontovanou náklady společnosti na kapitál. Poslední vhodnou změnou je úprava o hodnotu goodwillu, který byl odepsán z rozvahy. Běžným postupem po akvizici je kapitalizace a postupné odepsání goodwillu. Zastánci EVA však tvrdí, že se tím ztrácí část kapitálu, kterou při koupi do podniku vložili investoři. Young tedy navrhuje návrat takto odepsaného goodwillu do kolonky vlastního kapitálu. Výše uvedená varianta výpočtu EVA je tzv. varianta entity, která v sobě zahrnuje tvorbu hodnoty jako pro vlastníky, tak pro věřitele. Druhá varianta spočívá ve výpočtu EVA pouze z pohledu vlastníků. V této podobě ji uvádí např. Ministerstvo průmyslu a obchodu.

$$EVA = (ROE - r_e) * VK, \quad (4)$$

kde ROE je návratnost vlastního kapitálu, r_e jsou alternativní náklady na vlastní kapitál, jejich rozdíl je tzv. spread a VK je vlastní kapitál (MPO, 2016). Náklady na


vlastní kapitál jsou spočítány pomocí metodiky CAPM (Capital Asset Pricing Model), Je součtem bezrizikové sazby a rizikové přírážky, které se skládá z přírážky za finanční strukturu, finanční stabilitu, podnikatelské riziko a velikost podniku/likvidnost akcií. V tuto chvíli je bezriziková sazba stanovena jako výnos 10letých státních dluhopisů, poslední známá hodnota byla 0,37 %. Riziková přírážka za finanční stabilitu je navázána na likviditu a dosahuje hodnot 0-10 %. Přírážka za velikost podniku nabývá hodnot 0-5 %.

Koncept ekonomické přidané hodnoty si získal silnou pozornost, ačkoliv Chen a Dodd (1997) zmiňují, že se myšlenkově nejedná o novou věc. Ve 20. letech 20. století společnosti jako General Motors či DuPont používaly k hodnocení návratnost investic do jednotlivých divizí svého byznysu ROI (návratnost vloženého kapitálu). Ačkoliv cena kapitálu není v ROI zaznamenána, Chen a Dodd jsou přesvědčeni, že použití povede k podobným výsledkům jako použití EVA. Další koncept, který existoval dříve, je idea tzv. reziduálního příjmu definovaného jako rozdíl provozního příjmu a úroku z investovaného kapitálu.

EVA není uváděna izolovaně jako jeden ukazatel, ale jako komplexní přístup k řízení podniku a motivaci zaměstnanců. Mezi cíli investorů a managementu, hodnoceném na základě tradičních metrik, jako je míra ziskovosti, jsou přirozené rozdíly. Ty mohou vést ke krátkozrakému rozhodování výhodnému pouze z krátkodobého pohledu. EVA umožňuje nastavením hodnocení, jež je založeno na zvyšování hodnoty podniku v čase, tyto cíle sladit a změnit horizont rozhodování ve prospěch dlouhodobosti (Costigan & Lovata, 2002; Biddle a kol. 1999). Jedním ze známých případů využití EVA je společnost Coca Cola. Průměrný výnos akcií v období mezi lety 1987 a 1993 činil 200 %. O'Byrne, (1996), nachází vysokou korelaci mezi tržní hodnotou firmy a tvorbou EVA. Chen a Dodd (2001) porovnávají několik druhů metrik pocházejících z účetnictví a ve vztahu k výsledkům na burze a vidí EVA jako ukazatel dávající informaci navíc o ceně akcií, nicméně bez převahy nad ostatními ukazateli. Z toho vyplývá, že by bylo zajímavé z pohledu investorů umět odhadnout vývoj EVA a tím i investiční potenciál podniků. Jedinou prací, která se byť jen okrajově dotýká predikce EVA, byla práce Neumaierové (2005) na bankrotně-bonitním modelu IN05. Bankrotní část modelu je zastoupena predikcí selhání společnosti, bonitní část pak predikcí tvorby přidané hodnoty. Index IN05 má podobu:

$$IN05 = \frac{Aktiva}{Cizí zdroje} + 0,04 * \frac{EBIT}{\frac{Nákladové úroky}{Oběžná aktiva}} + 3,97 * \frac{EBIT}{Aktiva} + 0,21 * \frac{Výnosy}{Aktiva} + 0,09 * \frac{Výnosy}{Aktiva} \quad (5)$$

Po dosazení údajů je spočítána byla hodnota indexu porovnána s hraničními mezemi, které jsou 0,9 a 1,6. Níže je možné vidět úspěšnost indexu.



Obr. 1 Úspěšnost klasifikace případů IN05
Zdroj: Neumaierová, 2005.

Obrázek je převzat přímo z materiálů doc. Neumaierové. Bílá barva označuje bankrotující firmy, světle šedá zdravé firmy, tmavě šedá podniky tvořící hodnotu a černá podniky tvořící hodnotu. První 2 sloupce se vztahují k intervalu od $-\infty$ do 0,9, prostřední 2 sloupce k intervalu od 0,9 do 1,6 a poslední 2 sloupce k intervalu od 1,6 do ∞ . Jak je vidět, model si vede velmi dobře v krajních intervalech a ne moc dobře uprostřed, v tzv. šedé zóně. Bohužel nám není známo, zdali jsou toto výsledky testování klasifikace či predikce, tzn. testování na datech, na nichž byl model vytvořen, či na jiných. Dále není jasné, jaké jsou absolutní četnosti podniků v jednotlivých skupinách, proto je vyhodnocení skutečné síly modelu problematické.

2.4 Makroekonomické prostředí

V rámci modelu budou zařazeny proměnné z vnějšího, neboli makroekonomického prostředí společnosti. Bohužel nebyly nalezeny práce, které by se zabývaly přímým vlivem ekonomického prostředí na tvorbu EVA. Z důvodů absence této literatury, se zaměříme na obor nejbližší a to jsou práce, které zkoumají vliv makroekonomických proměnných na selhání podniku. Příkladem může být Virolainen (2004), jenž zkoumá vliv HDP, úrokových sazeb a zadluženosti podniků a všechny proměnné nachází významné.

Jakubík (2007) se zabývá vlivem HDP, nominální úrokové sazby a inflace na míru selhání podniků vyjádřenou jako podíl špatných (zesplatněných) úvěrů na celkovém množství. Zkoumá české prostředí a nachází spojitost mezi nezávislými proměnnými a bankrotem. Asi nejbližší této práci je z pohledu využití typu dat Bruneau a kol. (2012). Ti zkoumají vliv mikro a makro proměnných na bankrot francouzských společností. Jako metodu využili logit model, kde označení závislé proměnné hodnotou 1 u pozorování znamená firmu operující v čase $t-1$ a již neak-

tivní v čase t , označení hodnotou 0 firmu operující ve všech obdobích. Jako makroekonomické ukazatele použili úrokovou míru, GAP, což je zkratka pro output gap variable neboli rozdíl mezi skutečným a potenciálním produktem, míru inflace a nominální kurz Dolar/EUR. Jako mikroekonomické proměnné využili soustavu poměrových ukazatelů. Ty byly modelovány se zpožděním $t-3$ s dopadem v čase t , u makroekonomických ukazatelů dvě varianty $t-2$ a $t-3$ s dopadem v čase t . Byly modelovány tři varianty, přičemž makroekonomické ukazatele obsahovala pouze jedna. Všechny proměnné v obou variantách zpoždění byly nalezeny významné a znaménka koeficientů shodující se s teoretickými předpoklady.

Zmíněné modely naznačují, že zařazování vnějšího prostředí společností do modelů predikujících výsledky na individuálních úrovních (s výjimkou Jakubíka), dává informace navíc, které typicky podnikové proměnné nemusejí obsahovat. Na základě těchto studií bylo rozhodnuto, že makroekonomické proměnné budou zařazeny i v této práci, více o nich v praktické části.

2.5 Diskriminační a faktorová analýza

Data jsou ropou moderní doby. S masivním rozvojem IT kapacit je možné využít statistické metody schopné třídít, zařazovat a predikovat za účelem efektivní klasifikace v oblastech, které dříve byly příliš komplikované, nezajímavé anebo vůbec neexistovaly. Příkladem budiž praktické využití prediktivní analytiky u společnosti Netflix, která na základě informací o uživatelích doporučuje jim samotným vhodná videa. Společnost Tesco využívá data získaná díky svému věrnostnímu programu, kartě Clubcard. Pomocí prediktivní analytiky dokáží na Stanfordské univerzitě diagnostikovat lépe rakovinu prsu než lékař díky tomu, že počítač bere v potaz více faktorů (Siegel, 2014). Nejblíže oboru této práce jsou skoringové modely, pomocí nichž banky odhadují bonitu svých potenciálních klientů. Zmiňme na okraj práci od profesora Altmana z roku 1968, která tomuto položila základy.

Mezi nejpobulárnější metody prediktivní analytiky patří rozhodovací stromy, vícerozměrná diskriminační analýza či logistická regrese. Zajímavou možností je také využití neuronových sítí. V této práci je použita diskriminační analýza, neboť její použití v praxi firemních financí má dlouholetou tradici. Jako doplňková metoda pro lepší práci s daty je využita faktorová analýza.

Diskriminační analýza je metoda poprvé použita Ronaldem Fisherem v roce 1936 ke klasifikaci různých druhů kosatců na základě jejich charakteristik. Principem diskriminační analýzy je nalezení takové lineární kombinace p sledovaných proměnných v podobě

$$Y = \mathbf{v}^T \mathbf{x}, \quad (6)$$

kde

$$\mathbf{v}^T = [v_1, v_2, \dots, v_p] \quad (7)$$

je vektor parametrů, a která separuje K skupin tak, že její vnitroskupinová variabilita bude co nejmenší a meziskupinová co největší (Hebák a kol, 2007). Pokud vnitroskupinovou variabilitu proměnných označíme jako čtvercovou matici.

$$\mathbf{E} = \sum_{k=1}^K \sum_{i=1}^{n_k} (\mathbf{x}_{ki} - \bar{\mathbf{x}}_k)(\mathbf{x}_{ki} - \bar{\mathbf{x}}_k)^T, \quad (8)$$

a meziskupinovou variabilitu jako

$$\mathbf{B} = \sum_{k=1}^K \sum_{i=1}^{n_k} (\bar{\mathbf{x}}_k - \bar{\mathbf{x}})(\bar{\mathbf{x}}_k - \bar{\mathbf{x}})^T, \quad (9)$$

pak celková variabilita souboru jde zapsat jako

$$\mathbf{T} = \mathbf{E} + \mathbf{B}. \quad (10)$$

a míra meziskupinové a vnitroskupinové variability pro novou proměnnou lze zapsat jako $\mathbf{v}^T \mathbf{B} \mathbf{v}$ a $\mathbf{v}^T \mathbf{E} \mathbf{v}$. Nejlepší diskriminace pak dosáhneme při maximalizaci podílu

$$\lambda = \frac{\mathbf{v}^T \mathbf{B} \mathbf{v}}{\mathbf{v}^T \mathbf{E} \mathbf{v}}, \quad (11)$$

který se nazývá Fisherovo diskriminační kritérium. Pomocí parciálních derivací podle prvků vektoru \mathbf{v} a položením rovno nule získáme soustavu rovnic, díky nimž spočítáme tzv. charakteristická čísla sloužící k nalezení konečných vektorů.

$$Y = \mathbf{v}^T \mathbf{x}. \quad (12)$$

Rovnice výše se nazývá kanonická diskriminační funkce. Pro modelování dvou skupin si lze výsledek geometricky představit jako projekci bodů reprezentujících jednotlivá pozorování na přímku, kdy umístění pozorování na přímce je závislé na jejich tzv. skóre, tzn. hodnotě diskriminační proměnné (Y) a jejich zařazení do skupiny je závislé na vzdálenosti od střední hodnoty skóre pro každou ze skupin. Diskriminační analýza podléhá několika základním předpokladům:

- vícerozměrné normální rozdělení dat,
- homogenita rozptylu mezi skupinami,
- nezávislost průměrů a variance proměnných,
- náklady chybné klasifikace jsou známé.

Prvním třem předpokladům se budeme věnovat více v praktické části práce, ke čtvrtému předpokladu. Vochozka (2011) uvádí, že je často zanedbáván, v této práci se jemu z racionálních důvodů vyhneme. V principu se jedná o to, že při rozřazování pozorování do skupin vznikají chyby I. a II. typu, tzn. pozorování skupiny A je zařazeno do skupiny B či naopak. Pokud jsou negativní důsledky špatného rozřazení ekvivalentní, pak se nic neděje. V případě, že by např. u chyby II. typu náklady na nic výrazně převyšovaly náklady na chybu I. typu, pak by měla být sestavena

tzv. funkce celkové ztráty, která bude preferovat zařazování do první skupiny a tím minimalizovat četnost chyby II. typu. Jak podotýkám, toto je v literatuře hojně opomíjeno, výjimky vidí u Altmana a kol. (1977) a Tafflera (1982). V našem případě považujeme obě chyby za ekvivalentní z pohledu nákladů, tímto se tedy nebudeme zabývat.

Jako statistická metoda zkoumající vícerozměrná data však čelí diskriminační analýza při použití pro analýzu finančních dat jistým problémům. Poměrně dobře je shrnuje Vochozka (2011)

- Předpoklad bipolárně závislých proměnných
 - Toto kritérium naráží především u modelování bankrotu/bonity společností. Ty jsou rozděleny na krachující a nekrachující, přitom okamžik, ve kterém se firma dostane do úpadku, nemusí být z ekonomického pohledu tak jasný, jako z právního. V případě modelování tvorby EVA toto řešit nemusíme, na základě definovaného výpočtu je skutečnost jednoznačně určena.
- Metodika výběru souboru dat vzorových firem
 - Data, z nichž bývají modely vytvořeny, jsou často výsledkem nenáhodného výběru vzorků. Zmijewsky (1984) uvádí, že v takovém případě jsou výsledky ovlivněny v důsledku odhadované pravděpodobnosti výskytu skupin v populaci. Z toho poté vyplývá špatná predikční schopnost při použití na vzorcích nepocházejících z výběru. Na tyto skutečnosti je třeba buď explicitně upozorňovat uživatele modelu, případně vhodně rozšířit datovou základnu.
- Nestacionarita a nestabilita dat vstupních souborů
 - Aby mělo smysl model vytvářet, musí být schopen predikovat případy, které teprve nastanou. Model je vytvořen na datech z určitého časového intervalu, ve kterém existují jisté vztahy mezi závislou a nezávislými proměnnými, které se navenek projeví v koeficientech diskriminační funkce a schopnosti predikce. Aby bylo možno využít model úspěšně i v následném období, tyto vztahy by měly zůstat konstantní. Taffler (1984) zmiňuje testování úspěšnosti na z pohledu modelu budoucích datech. Keasey a Watson (1991) tvrdí, že modely vytvořené dlouhou dobu před jejich použitím jsou již neplatné a je potřeba je aktualizovat.
- Využití ročních finančních výkazů z účetní závěrky
 - Tomuto problému jsme se již věnovali v části týkající se finanční analýzy.
- Výběr nezávislých proměnných
 - Dle Vochozky (2011) dochází k problémům při výběru počátečních proměnných a k tomu, jak je s nimi zacházeno během modelování. Zmiňuje se o tomto problému především ve spojitosti s tvorbou bankrotních modelů. Proměnné, rozumějte poměrové ukazatele, jsou vybírány na základě popularity a četnosti použití v předcházející li-

teratuře, což činí modely poměrně jednostranně zaměřenými. Dalším problémem je jistá absence kompletní ucelené teorie, která by se vyjadřovala k tomu, jaký vliv mají nezávislé proměnné na závislou vlastně mít. To se projevuje při zkoumání validity modelu, kdy znaménka koeficientů jsou záměrně přehlížena, hledí se pouze na výpočetní výsledek. Věcná stránka je tak zatlačena dozadu.

- Časová dimenze
 - Na problém s časovým nesouladem mezi tvorbou modelu a jeho uplatněním v praxi se dá nahlížet ještě jiným způsobem, než bylo popsáno o výše. Z důvodu porušování předpokladů stability vztahů mezi proměnnými v čase nelze očekávat, že model bude schopen kvalitní predikce. Proto je není vhodné nahlížet na výsledek jako na něco schopné předpovídat konkrétní výsledek u neznámých spoečností, ale jako na metodu, která pouze nahlíží na společnosti jako na sobě podobné bez silné predikční síly a blíží se tak spíš nějaké deskriptivní statistice než modelu predikce. S ohledem na chybějící finanční teorii, která by se týkala příčinných vztahů, se dá říci, že metoda pouze popisuje míru podobnosti mezi skupinou a neznámým pozorováním. Nicméně testováním pomocí externích dat, se dá zcela jasně odvodit procentuální míra úspěšnosti a metoda samotná si zakládá na míře podobnosti parametrů pozorování s parametry skupin a z toho vyplývající příslušnosti k nim.

Nyní ještě krátce k faktorové analýze. Faktorová analýza je průzkumná statistická metoda sloužící ke snížení množství proměnných popisující soubor dat. V případě, že jsou mezi sebou proměnné korelovány, je možné nalézt funkci, která bude jejich lineární kombinací schopnou vysvětlit původní veličiny.

Nová proměnná se nazývá faktor a její vztah k původním proměnným se dá kvantifikovat pomocí tzv. faktorových zátěží interpretovatelných jako korelační koeficienty mezi ní a původními proměnnými (Statsoft, 2016). V případě, že zkoumáme data, u kterých očekáváme více faktorů, tzn. rozdělení do více skupin, počet skupin explicitně zvolíme pomocí tzv. vlastních čísel reprezentujících míru vysvětlené variability celkového souboru. Faktorová analýza je závislá na věcné interpretaci faktorů a jejich skutečném významu. Faktory by neměly být považovány za vhodné k dalšímu modelování, aniž by za jejich vznikem nestála vhodná teorie. Jinak hrozí zkreslení výsledků. Faktorová analýza bývá prováděna pouze na určitém vzorku dat, v případě špatné metodiky jejich výběru může dojít k vytvoření umělé korelační struktury, jejíž smysl může být pouze matematický a odporující teorii i rozumu, pro výsledky tedy nevhodný.

3 Praktická část

3.1 Metodika

Praktická část je členěna na několik sekcí, které chronologicky odpovídají postupu při modelování. Konečným výsledkem práce budou matematické modely schopné s určitou pravděpodobností predikovat, zdali bude ukazatel EVA u konkrétní společnosti nabývat kladných či záporných hodnot za rok od data odhadu, tzn., bude modelována EVA v čase $t+1$ na základě dat z času t . Práce probíhala takto.

1. Stažení dat z databáze Amadeus, stránek Ministerstva Průmyslu a Obchodu (MPO) a stránek Českého statistického úřadu (ČSÚ).
2. Výpočet poměrových ukazatelů pro všechna pozorování společně s přiřazením makroekonomických proměnných.
3. Očištění dat,
 - 3.1. Odstranění pozorování s chybějícími hodnotami,
 - 3.2. Odstranění pozorování s podezřelými či těžko interpretovatelnými hodnotami jako jsou např. záporný vlastní kapitál atp.
 - 3.3. Odstranění tzv. extrémních pozorování, tzn. pozorování příliš vzdálených od průměrů, pokud to bylo vhodné.
4. Snížení počtu nezávislých proměnných prostřednictvím korelačních matic a faktorové analýzy.
5. Tvorba modelů v programu STATISTICA.
 - 5.1. Otestování předpokladů modelů.
 - 5.1.1. Otestování vícerozměrného normálního rozdělení pomocí Kolmogorova-Smirnova testu a Q-Q grafů.
 - 5.1.2. Otestování shodnosti kovariančních matic pomocí Boxova M testu.
 - 5.1.3. Otestování míry korelace mezi kategorizovanými průměry a rozptyly pomocí korelační matice.
 - 5.2. Vytvoření modelů pomocí krokové dopředné metody.
 - 5.3. Vyhodnocení klasifikační síly modelů.
6. Testování predikční síly modelů na datech nezařazených do modelování a porovnání jejich síly.

3.2 Data

3.2.1 Popis základních dat a nezávislých proměnných

Základními kameny modelování jsou data. Pro potřeby této práce, jak již bylo výše zmíněno, byla použita data pocházející ze tří zdrojů, a to z databáze Amadeus, stránek MPO a stránek ČSÚ.

Databáze Amadeus obsahuje informace o podnicích působících v řadě států Evropy. Jedná se o kvalitativní i kvantitativní data, zejména o položky z rozvah, výkazů zisku a ztrát a vypočítané poměrové ukazatele. Pro účely modelování byla stažena data v časovém horizontu deseti let, roky 2005 až 2014. Takto dlouhá časová řada byla zvolena z důvodů docílení vyšší robustnosti výsledků modelu. Častými výtkami u podobných typů analýz bývají kritiky nevěrohodnosti z důvodů zařazení dat z omezeného časového okna. Modely tak bývají natrénovány pouze na jedno konkrétní prostředí, a pokud jsou použity za jiných podmínek, selhávají. Kritika z druhé strany říká, že problémem může být naopak využití dat z delšího časového úseku z důvodu v čase se měnících vztahů mezi proměnnými (Vochozka, 2011). Koeficienty u modelů vzniklých z dat z různých časových okamžiků mohou být značně nekonzistentní a model podává v rámci predikce špatné výsledky. Více o tom, jakým způsobem s touto obavou bylo naloženo, je v části o testování kvality modelu. Strategie výběru počátečních dat je popsána v Tabulce 7.

Tab. 7 Posloupnost filtrování dat v databázi Amadeus

| Krok vyhledávání | Počet výsledků po vyfiltrování |
|---|--------------------------------|
| Všechny aktivní společnosti a společnosti bez známého stavu | 20 157 242 |
| Země: České republika | 477 276 |
| Obrat: všechny společnosti se známou hodnotou v roce 2014 | 98 963 |
| Minimální hodnota celkových aktiv v roce 2014 je 1 milion korun | 66 397 |

Toto pravidlo bylo využito u všech let a v každém roce tak bylo nalezeno a staženo 66 397 případů. Poslední 2 podmínky byly neustále uplatňovány vůči roku 2014, u starších ročníků tedy chybějí data ke společnostem, které ještě nemusely v té době existovat. Celkem šlo o společnosti spadající do 13 sekcí dle odvětvové klasifikace NACE, viz Tabulka 2.

Tab. 8 Rozdělení hospodářství dle NACE: modelované skupiny

| NACE | Sekce hospodářství |
|-------------|------------------------------------|
| A | ZEMĚDĚLSTVÍ, LESNICTVÍ A RYBÁŘSTVÍ |
| B | DOBÝVÁNÍ A TĚŽBA |
| C | ZPRACOVATELSKÝ PRŮMYSL |
| D | VÝROBA A ROZV. ELEKT. PLYNU, |
| E | VODA; ODPADY A SANACE |
| F | STAVEBNICTVÍ |
| G | VELKO A MALOOBCHOD; OPR.V. |
| H | DOPRAVA A SKLADOVÁNÍ |
| I | UBYTOVÁNÍ, STRAV. A POH. |
| J | INFORM. A KOMUN. ČINNOSTI |
| L | ČINN. V OBLASTI NEMOVITOSTÍ |
| M | PROF., VĚDEC. A TECHN. ČINN. |
| N | ADMINISTR.A PODP. ČINNOSTI |

Dataset z Amadea obsahuje v základu 26 proměnných popisujících rozvahu, 25 proměnných týkajících se výkazu zisku a ztrát a 32 poměrových ukazatelů. K těmto bylo na základě literatury dopočítáno dalších 33 poměrových ukazatelů (Kislingarová a Hnilica, 2008, Chen a Shimerda, 1981) tak, aby se počáteční výběr vhodných proměnných co nejvíce rozšířil. Poměrové ukazatele byly spočteny z dat vztahujících se k rozvaze a výsledovce.

Využití poměrových ukazatelů je výhodnější než využití přímých dat rozvahy a výsledovky. Klasickými veličinami, ke kterým se sledovaná veličina vztahuje, bývají určitá bilanční suma, aktiva či tržby. Výpočet zajišťuje standardizaci, kdy je pak relevantní srovnávat mezi sebou výsledky malých společností s výsledky společností velkých, stejně tak různé výsledky v rámci jedné společnosti v čase.

Dohromady bylo shromážděno 65 ukazatelů, 60 jako použitelných pro další práci, u 5 bylo zjištěno velmi málo hodnot, proto byla odstraněna. Kompletní přehled proměnných je uveden v příloze práce.

V tuto chvíli každý rok obsahoval svých 66 397 případů, u mnoha z nich však chyběly základní údaje z rozvahy i výsledovky, proto nemohly být spočítány poměrové ukazatele a bylo nutné datovou základnu o tyto případy očistit. Stejně tak se postupovalo u pozorování, u nichž se hodnoty ukazatelů vymykaly očekávaným hodnotám, tzn., měly buď jiné znaménko, nebo dosahovaly velmi extrémních hodnot. Hranice, od které byly hodnoty považovány za extrémní, byla v tomto případě určena arbitrárně. Konkrétní seznam úprav je uveden v Tabulce 9, X označuje spočítané hodnoty u daných ukazatelů.

Tab. 9 Úpravy o pozorování s extrémními hodnotami

| Proměnné, u nichž byla provedena úprava | Interval ponechaných hodnot |
|---|-----------------------------|
| Proměnné spojené s rentabilitou jako ROA, ROE, ROCE apod. + další proměnné vyjádřené jako procentní podíl | $-1 < X < 1$ |
| Finanční páka | $X < 10$ |
| Doba obratu aktiv | $X < 2000$ |
| Doba obratu zásob | $X < 360$ |
| Capital Turnover: Current Assets/Total Assets | $X < 1$ |
| Financial Leverage (Current Assets - Current Liabilities)/(Long Term Debt+Loans) | $-1 < X < 1$ |

Po těchto úpravách bylo k dispozici několik desítek tisíc pozorování. Jejich množství bylo dále sníženo na přijatelné z technických důvodů. I přes relativně slušné vybavení výpočetní technikou trvaly zezачátku úpravy dat neúměrně dlouhou dobu. Proto bylo pro každý rok náhodně vybráno 200 pozorování za každý obor, pokud bylo k dispozici. Zůstalo celkem 13619 pozorování napříč lety a obory.

Dále je potřeba věnovat pozornost korelační struktuře mezi nezávislými proměnnými. Valná část z nich měla stejnou vztažnou či sledovanou veličinu. Tyto ukazatele zkoumají danou problematiku z prakticky stejného úhlu a tím poskytují jednu a tutéž informaci. Pro budoucí odlišení skupin je tato duplikace proměnných zbytečná, dokonce až nežádoucí v případě, že by byly veličiny zcela závislé. Bylo tedy nutné snížit množství proměnných tak, aby pokrývaly různé části rozvahy a výsledovky, poskytovaly kompletní obraz společností a zároveň se příliš nepřekrývaly svým významem. Z matematického pohledu se jedná o sestavení skupin proměnných, jež jsou mezi sebou vysoce korelované a následně vybrání nejvhodnější z nich. K tomu byla použita korelační matice společně s faktorovou analýzou.

Nejdříve byly na základě párových korelačních koeficientů vyfiltrovány proměnné, které k sobě měly relativně blízko. Hranicí byla korelace nižší než -0,6 a vyšší než 0,6. Celkem vzniklo 7 skupin. Posléze byla na každou ze skupin použita faktorová analýza. Jejím účelem bylo dále rozmělnit skupiny na menší části a vybrat vhodné reprezentanty do modelů. Faktorová analýza funguje na principu vytváření nových proměnných, které zachycují co nejlépe vzájemné vztahy mezi reálnými proměnnými, tím redukuje jejich potřebné množství a snižují náročnost výpočtů. Nové proměnné se nazývají faktory a míra toho, jak moc pokrývají každou z původních proměnných, se nazývá faktorová zátěž. Tu lze interpretovat jako míru korelace mezi novou a původními proměnnými.

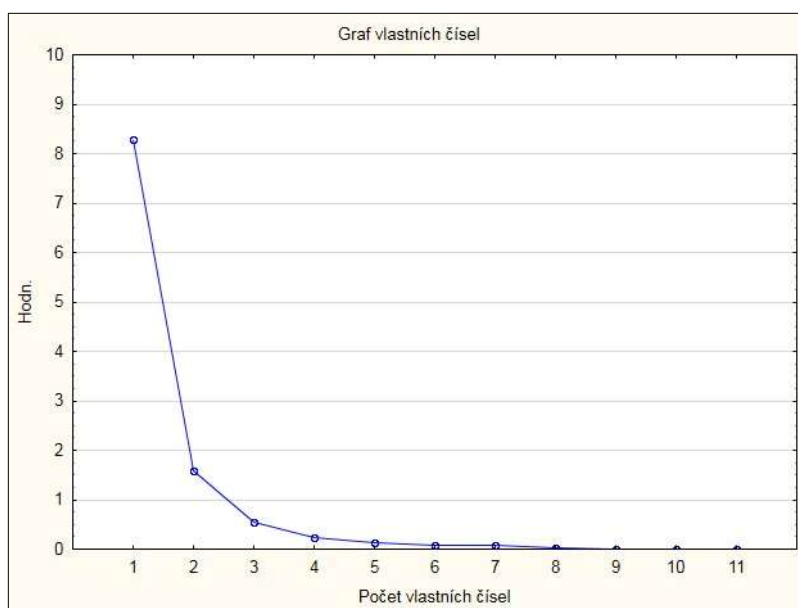
V Tabulce 10 lze pro ilustraci vidět 1. zkoumanou skupinu. Jedná se o ukazatele rentability z Amadea v různých podobách s poměrem Cash flow vůči tržbám

a ukazatelem Solvency ratio ukazujícím velikost aktiv financovaných vlastníky kapitálem (vlastní kapitál/celková aktiva).

Tab. 10 První skupina proměnných pro faktorovou analýzu

| Poměrové ukazatele pro faktorovou analýzu | |
|--|---|
| ROE using P/L before tax % 2005-2013 | Profit margin % 2005-2013 |
| ROCE using P/L before tax % 2005-2013 | EBITDA Margin % 2005-2013 |
| ROA using P/L before tax % 2005-2013 | EBIT Margin % 2005-2013 |
| ROE using Net income % 2005-2013 | Cash flow / Operating revenue % 2005-2013 |
| ROCE using Net income % 2005-2013 | Solvency ratio (Asset based) % 2005-2013 |
| ROA using Net income % 2005-2013 | |

Nejdříve proběhl odhad počtu faktorů (nových proměnných). Jednou z metod je sutinový graf, který zobrazuje tzv. vlastní čísla představující míru variability původní proměnné krytou novou proměnnou. Doporučené hodnoty jsou vyšší než 1, v našem případě jde o 2 faktory.



Obr. 2 Sutinový graf pro první skupinu proměnných

Dalším krokem bylo ověření skutečné velikosti variability, kterou 2 faktory pokrývají.

Tab. 11 Tabulka vlastních čísel pro první skupinu proměnných

| | vl. číslo | % celk. (rozptylu) | Kumulativ. (vlast. číslo) | Kumulativ. (%) |
|----------|------------------|-------------------------------|--------------------------------------|---------------------------|
| Faktor 1 | 8,286009 | 75,32736 | 8,286009 | 75,32736 |
| Faktor 2 | 1,585179 | 14,41072 | 9,871189 | 89,73808 |

V Tabulce 11 je vidět, že první faktor vyplňuje 75 % variability a druhý 14 %, dohromady tedy 89 %, což je slušné (maximum je 100 %), na řadě je přiřazení ukazatelů do skupin pomocí faktorových zátěží.

Tab. 12 Faktorové zátěže pro první skupinu proměnných (Varimax rotace)

| Proměnná | Faktor (1) | Faktor (2) |
|---|-------------------|-------------------|
| ROE using P/L before tax % 2005-2013 | 0,939230 | 0,257831 |
| ROCE using P/L before tax % 2005-2013 | 0,930960 | 0,288069 |
| ROA using P/L before tax % 2005-2013 | 0,867803 | 0,418031 |
| ROE using Net income % 2005-2013 | 0,940965 | 0,255179 |
| ROCE using Net income % 2005-2013 | 0,931598 | 0,289319 |
| ROA using Net income % 2005-2013 | 0,866939 | 0,409533 |
| Profit margin % 2005-2013 | 0,558269 | 0,719344 |
| EBITDA Margin % 2005-2013 | 0,285048 | 0,933621 |
| EBIT Margin % 2005-2013 | 0,506318 | 0,778026 |
| Cash flow / Operating revenue % 2005-2013 | 0,290215 | 0,922674 |
| Solvency ratio (Asset based) % 2005-2013 | 0,223556 | 0,770980 |

Jak bylo výše řečeno, faktorové zátěže se dají interpretovat jako korelace mezi původními proměnnými a faktorem, proměnná je tedy přiřazena k faktoru, se kterým má vyšší korelaci. Výše vidíme přesné rozdělení do 2 skupin. První faktor by se dal interpretovat jako rentabilita zisku, neboť všechny proměnné, které jej zkoumají, se zabývají ziskem. První 3 zkoumají zisk před zdaněním, další 3 čistý zisk. Pro druhý faktor mají všechny proměnné s výjimkou Solvency ratio společnou proměnnou ve jmenovateli, k níž se vztahují, jsou to tržby. Zkoumanou částí jsou různé úrovně zisku. Dal by se tedy popsat jako míra schopnosti podniku dostat ze svých tržeb co nejvíce.

Je vidět, že ukazatele ve skupinách nesou prakticky totožné informace a mělo by být postačující vybrat k modelování pouze jeden z nich. Byly vybrány proměnné s nejvyšší faktorovou zátěží v každé skupině, neboť ty pokrývají nejvíce variability (mají nejvyšší korelaci s faktorem, který reprezentuje všechny proměnné ve skupině). V první skupině to je proměnná „ROE using Net income % 2005-2013“ s faktorovou zátěží 0,940965, ve druhé „EBITDA Margin % 2005-2013“ s faktorovou zátěží 0,933621. Ostatní ukazatele byly z modelování vyloučeny.

Stejný postup byl aplikován na všech 7 skupinách proměnných, které vznikly pomocí korelační matice. Rozhodování o zařazení do faktorové analýzy bylo také podmíněno mírou korelace ukazatelů s modelovanou proměnnou EVA (o níž pojednává další kapitola) a tak byl jeden ukazatel vyřazen, do faktorové analýzy jich tedy vstupovalo 59. Celkový přehled lze vidět níže v tabulce.

Tab. 13 Skupiny, na něž byla aplikována faktorová analýza

| Název skupiny dle faktorů | Původní počet proměnných | Počet proměnných vstupujících do modelování |
|--|--------------------------|---|
| Rentabilita- ukazatele z Amadea | 11 | 2 |
| Rentabilita- dopočítané ukazatele | 7 | 2 |
| Ukazatele na zaměstnance | 7 | 4 |
| Likvidita | 7 | 3 |
| Krytí dluhu | 3 | 1 |
| Doby obratu a finanční páka | 14 | 5 |
| Proměnné, které nejsou korelované s žádnými z předchozích skupin | 10 | 10 |
| Celkem | 59 | 27 |

Můžeme vidět, že faktorová analýza významně snížila počet proměnných vstupujících do modelování odstraněním těch, které poskytovaly duplicitní informace. Kompletní seznam všech 27 poměrových ukazatelů vstupujících do modelování

pohromadě je možné nalézt v příloze. Jako nezávislá proměnná navíc byla spočítána EVA (dále v práci s indexem 0 v případě, že budeme hovořit o EVA jako o nezávislé proměnné, nikoliv modelované) dané společnosti náležející do stejného roku, jako ostatní nezávislé proměnné, tzn., byla zkoumána možná „trendovost“ ve výkonnosti podniku a tvorby hodnoty jako determinant budoucí EVA.

Dalším typem nezávislých proměnných jsou veličiny popisující makroekonomické prostředí. Poskytovatelem dat byl Český statistický úřad (ČSÚ, 2016a). Z jeho webových stránek byly staženy makroekonomické ukazatele pro Českou republiku a to ve stejném časovém rozsahu, jako u dat firemních. Celkově se jednalo 65 proměnných zařazených do 3 kategorií:

- Ukazatele reálné ekonomiky zobrazují výkonnost ekonomiky, pohyb cen a rozdělení důchodů.
- Měnové ukazatele zobrazují vývoj českého vývozu a dovozu, nejdůležitějších kurzů, různé typy platební bilance a údaje o devizových rezervách.
- Fiskální ukazatele zobrazují salda hospodaření státního rozpočtu a dluh ČR.

Na základě korelační matice bylo k modelování vybráno 11 ukazatelů. Ty můžeme vidět v tabulce níže. Všechny původní proměnné jsou pak uvedeny v příloze.

Tab. 14 Makroekonomické proměnné vstupující do modelů

| Proměnná | Jednotky |
|-----------------------------|-----------------|
| HDP | %, r/r, reálně |
| Výdaje na konečnou spotřebu | %, r/r, reálně |
| Jednotkové pracovní náklady | %, r/r |
| Zemědělství- tržby | %, r/r, reálně |
| Obecná míra nezaměstnanosti | %, průměr |
| CZK/EUR | CZK/EUK průměr |
| Míra inflace | %, r/r, průměr |
| Ceny průmyslových výrobců | %, r/r, průměr |
| Ceny tržních služeb | %, r/r, průměr |
| Ceny vývozu zboží | %, r/r, průměr |
| Ceny dovozu zboží | %, r/r, průměr |

Celkový počet proměnných plně k dispozici je 27 firemních a 11 makroekonomických ukazatelů, celkem tedy 38.

3.2.2 Popis modelované proměnné

Jako závislá, v našem případě kategorizující proměnná je ekonomická přidaná hodnota, EVA (Economic Value Added). Pro naše pozorování se nenachází přímo spočítaná v žádném ze zdrojů, proto ji bylo nutnou dopočítat zvlášť. Pro připomenutí, základní vztah pro výpočet EVA je:

$$EVA = NOPAT - WACC * C, \quad (13)$$

kde NOPAT je „Net operating profit after taxes“ neboli čistý provozní zisk po zdanění, WACC je „Weighted Average Cost of Capital“, což jsou vážené náklady na kapitál a C označuje veškerý kapitál, za nějž je požadován úrok či dividendy.

Pro každé pozorování bylo nutno zjistit všechny 3 veličiny a provést výpočet. NOPAT pochází z výsledovky, nicméně mezi 25 původními proměnnými z Amadea jej nenajdeme. Dle MPO (2016) je vhodné v případě absence tuto veličinu nahradit ukazatelem EBIT, což je zisk před zdaněním a úroky. Ten se již mezi daty nachází, dokonce s popisem, že se vztahuje pouze k provozní činnosti.

Další, pro výpočet požadovanou veličinou, je veškerý „úročný“ kapitál. Jedná se o kompletní vlastní kapitál a z pohledu cizího kapitálu jde o veškerý úrok nesoucí kapitál, tzn. dlouhodobé a krátkodobé úvěry. Vše máme z databáze Amadeus k dispozici v podobě 3 proměnných pod názvy „Shareholder funds“, „Long Term Debt“ a „Loans“. Jejich prostým sečtením obdržíme celkový úrok a dividendami zatížený kapitál.

Poslední zbývající proměnnou je WACC. Samotný výpočet WACC vypadá obecně takto:

$$WACC = \frac{CK}{K} * n_{CK} * (1 - d) + \frac{VK}{K} * n_{VK}. \quad (14)$$

Jak je vidět, je nezbytné znát předem náklady cizího a vlastního kapitálu. Jako náklady cizího kapitálu lze brát poměr úroků a jistiny. Pro zjištění nákladů VK je možno využít stavebnicový model CAPM, který náklady kvantifikuje na základě kritérií hodnotících rizikovost společnosti. Pro každou jednotlivou společnost by se však jednalo o relativně složitý postup výpočtu s ohledem na množství pozorování. Proto byly z dokumentů MPO využity již vypočítané hodnoty WACC platné pro jednotlivá odvětví. Směrem do minulosti data u některých sekcí chybí, tudíž jsou použita nejstarší známá. U let 2005 a 2006 je tak relativně velké množství hodnot doplněno z roku 2007.

WACC je spočítáno v kontextu ratingového modelu INFA manželů Neumaierových a to za několika zjednodušujících podmínek.

1. Cena cizího kapitálu je substituována skutečnou či odhadovanou úrokovou mírou.
2. Předpokládá se nezávislost hodnoty vážených průměrných nákladů na kapitál na kapitálové struktuře.
3. Ve vzorci WACC je místo vlivu zdanění v podobě $(1-d)$ použit podíl čistého zisku na zisku, tzn. je zohledněn skutečný vliv zdanění.

Všechny společnosti v daném konkrétním odvětví a roce mají uvažované stejné WACC.

Po získání všech vstupů byla spočítána o rok zpožděná EVA pro každé pozorování a následně přeměněna v binární proměnnou ve smyslu tvorby/ničení kapitálu (Kladná/Záporná). Po očištění dat mělo 7723 pozorování zápornou EVA 5896 pozorování kladnou EVA. To napříč všemi lety a obory.

3.3 Testování předpokladů

Metoda diskriminační analýzy je průzkumná technika vyžadující, aby vstupní data splňovala několik statistických předpokladů. Předpoklady byly testovány na datech určených pro vytvoření celkového modelu. V případě rozdělení dat na menší části z důvodů tvorby samostatných oborových modelů máme za to, že tyto podmnožiny splňují či nesplňují předpoklady tak, jak bylo zjištěno na celé množině dat.

3.3.1 Vícerozměrné normální rozdělení

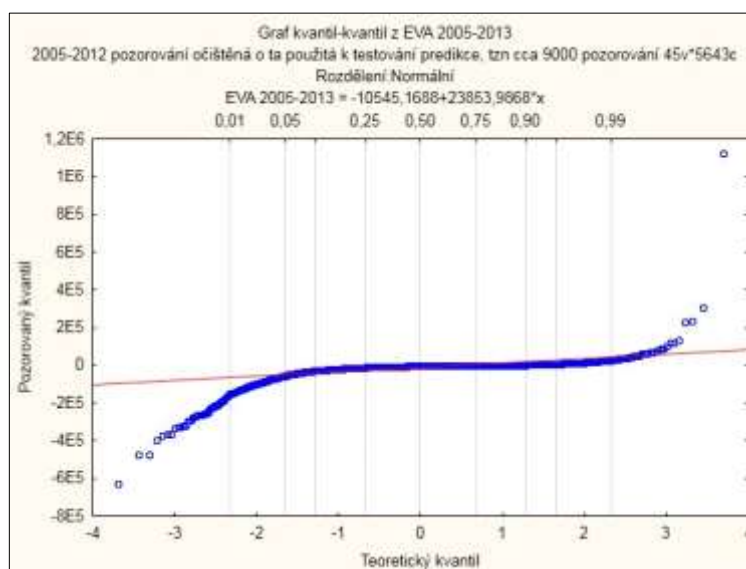
Klasickým předpokladem u jakékoliv metody, která v sobě zahrnuje průzkum vícerozměrných dat (např. MANOVA) je, že data pocházejí z vícerozměrného normálního rozdělení. Předpoklad normality je v praxi hojně porušován z čistě jednoduchých příčin. Data v reálném světě tomuto rozdělení někdy neodpovídají, nicméně porušení toho charakteru nejsou považována za fatální. Možným řešením je transformace dat pomocí vhodné transformační funkce (Vaníček, 2011). Bylo otestováno všech 28 podnikových ukazatelů určených k modelování vizuálně pomocí histogramů a pomocí Kolmogorova-Smirnova testu a Q-Q grafů. Udávaná síla testu není tak velká jako je např. Shapiro-Wilkův test, ten je ale určen primárně pro mnohem menší výběry. Makroekonomické ukazatele zkoumány nebyly, neboť počet pozorování je roven počtu zkoumaných let (9) a předpoklady normality u nich byly předem vyloučeny.

U všech 28 proměnných byla zamítnuta nulová hypotéza o normálním rozdělení, kdy p-hodnota K-S testu byla menší než 0,01. Důvody si ilustrujeme na typickém případu s pomocí proměnné EVA₀. Nejdříve si vykreslíme tabulku četností.

Tab. 15 Tabulka četností EVA₀ pro záporná pozorování

| Intervaly | Skutečná četnost | Očekávaná četnost | Skut. rel. četnost (%) | Oček. rel. četnost |
|----------------------------|------------------|-------------------|------------------------|--------------------|
| -10 000 000 <x<=-5 000 000 | 1 | 0 | 0,017 | 0,000 |
| 5 000 000 <x<=0 | 4384 | 3451 | 77,689 | 61,151 |
| 0 <x<=5 000 000 | 1257 | 2192 | 22,275 | 38,849 |
| 5 000 000 <x<=10 000 000 | 0 | 0 | 0,000 | 0,000 |
| 10 000 000 <x<=15 000 000 | 1 | 0 | 0,017 | 0,000 |
| Celkem a kumulovaně | 5843 | 5843 | 1 | 1 |

Rozdělení do zkoumaných tříd bylo hrubě ovlivněno několika odlehlými hodnotami. Tomu odpovídá i níže vykreslený Q-Q graf, který jde o něco dál a ukazuje, že by nestačilo pouze vyčlenit pár odlehlých hodnot.

Obr. 3 Q-Q graf, EVA₀

Žádná další pozorování tedy odstraňovat nebudeme, neboť porušení normality není považováno za fatální chybu znehodnocující výsledky.

3.3.2 Shodné kovarianční matice

Druhým předpokladem jsou shodné kovarianční matice napříč skupinami. Testováno pomocí Boxovy M statistiky, která je nicméně citlivá na porušení normality, tudíž její výsledky mohou být mírně zkreslené.

Tab. 16 Výsledek testování síly modelu.

| | Boxovo M | Chí-kvadrát | Stupně volnosti | p-hodnota |
|----------|-----------------|--------------------|------------------------|------------------|
| Boxovo M | 53024,47 | 52858,93 | 406 | <0,001 |

Výše v tabulce máme výsledek testu, statistika dosahuje naprosto nevídané výše a p-hodnota je nižší než nula. Zřejmě zde působí negativní vliv toho, že data nepocházejí z normálního rozdělení. Proto byl použit Leveneův test, který pro drtivou většinu proměnných také zamítl H_0 o rovnosti rozptylů. Způsobem, jak se tím vyrovnat je využití kvadratické diskriminační funkce namísto lineární, což je ale značně nepraktické, výsledky trpí na odchylky od normality. Zůstaneme tedy u původní specifikace s vědomím nesplnění tohoto předpokladu.

3.3.3 Nezávislost průměrů a směrodatných odchylek proměnných

Posledním předpokladem je absence silné korelace mezi průměry a směrodatnými odchylkami proměnných. Rozhodování o zařazení proměnných do modelu je založeno na testech významnosti počítaných jako poměr meziskupinové variability a průměrné vnitroskupinové variability. V případě, že meziskupinová variabilita je vyšší, než vnitroskupinová, pak proměnná přispívá k diskriminaci a je zařazena.

Může se však stát, že proměnná obsahuje vzdálená pozorování, která významně zvyšují variabilitu, tím i průměr a tak uměle navyšují meziskupinovou variabilitu pro danou proměnnou a tím její význam. V případě porušení předpokladu je vhodné prozkoumat kategorizované četnosti pomocí krabicových grafů pro zjištění, jestli se jedná o skutečnou diskriminaci anebo jen o nadhodnocení testů rozhodovacího procesu.

Tab. 17 Prověření korelace mezi průměry a rozptyly

| | Průměry | Sm. Odch. | Průměr | SM Odch |
|---------|----------------|------------------|-----------------|-----------------|
| Průměr | 1155,65 | 6200,60 | 1,000000 | 0,935381 |
| SM odch | 11159,12 | 46431,24 | 0,935381 | 1,000000 |

Jak je vidět, průměry a směrodatné odchylky jsou relativně silně korelovány. U závěrečných modelů budou proměnné zkontrolovány pomocí párových t-testů o rovnosti průměrů a kategorizovaných krabicových grafů.

3.4 Výstavba a testování modelů

Tvorba modelů je realizována pomocí metody lineární diskriminační analýzy a to prostřednictvím krokové dopředné metody. Ta je založena na postupném přidávání proměnných do modelů na základě hodnot F-testů spočítaných jako poměr mezi skupinové a vnitroskupinové variability. Proměnné s vyšší hodnotou jsou zařazeny do modelu, neboť přispívají nejvíce k rozlišování mezi skupinami. Proces skončí ve chvíli, kdy už žádná proměnná, která by byla přidána, významně nezvýší klasifikační sílu modelu.

Zvolit vhodný konečný počet proměnných v modelu je klíčová věc. Pokud předpokládáme, že žádná z proměnných není schopna rozlišovat mezi sebou skupiny extrémně dobře, pak malý počet proměnných povede k modelu podávajícímu špatné výsledky. Na druhou stranu příliš velký počet proměnných nejen že zhoršuje uvedení modelu do praxe, ale především hrozí jeho přeučení na datech. Tzn., že model si příliš zvykne na danou strukturu dat, na kterých jen „naučen“. Na první pohled podává skvělé výsledky, ale pokud by měl predikovat zařazení do skupiny u pozorování s neznámým výsledkem, úspěšnost může být tristní. Pro účely této práce bylo po několika zkušebních modelováních rozhodnuto končit s modelováním po přidání 5 proměnných. Výjimkou byly případy, kdy 5. či jedna z dříve přidávaných proměnných již očividně nepřidávala diskriminační sílu a proto bylo proměnných méně, či naopak.

Kritérium kvality modelu, pomocí něž je možné se řídit průběžně během tvorby, se nazývá Wilkova lambda. Je obdobou koeficientu determinace u regresní analýzy s tím rozdílem, že při nejlepší možné diskriminaci lambda nabývá hodnoty 0 a při žádné diskriminaci 1. Výsledná podoba modelu je soustava rovnic lineárních diskriminačních funkcí, pomocí nichž lze přímo klasifikovat jakékoliv pozorování. Pro každou skupinu je vytvořena rovnice ve tvaru

$$Score_i = a_i + b_{i1}x_1 + b_{i2}x_2 + \dots + b_{im}x_m, \quad (15)$$

kde x jsou pozorované hodnoty m -té nezávislé proměnné, b_i jsou příslušné koeficienty v i -té skupině pro m -tou proměnnou a $Score_i$ je výsledné skóre. Po dosazení hodnot je skóre spočítáno pro každou skupinu a pozorování spadá to té, kde nabývá vyšší hodnoty. V této práci budeme třídit pozorování do skupin touto cestou.

Dalším způsobem, jakým lze určit příslušnost, je kanonická diskriminační funkce, která obecně nabývá stejného tvaru, jako výše uvedená. Jde však pouze o jednu rovnici, pomocí níž se spočítá skóre. K tomu je známá střední hodnota skóre všech pozorování uvnitř skupin, tzv. skupinové centroidy. Zkoumaný případ je pak zařazen podle toho, ke kterému centroidu má blíže.

Kvalita modelu se v konečném důsledku hodnotí pomocí dvou kritérií. Tím první je úspěšnost klasifikace, což je schopnost modelu zařadit správně do skupin data, na nichž byl vytvořen. K tomu se používá tzv. klasifikační matice, kdy na hlavní diagonále jsou správně zařazené případy a na vedlejší nesprávně zařazené případy. Úspěšnost je pak definována jako poměr součtu všech prvků na hlavní diagonále a celkovým množstvím hodnocených případů. Ačkoliv je tuto užitečnou charakteristiku znát, hlavním účelem modelu není naučit jej určovat zařazení u dat, u kterých už zařazení známe. Mnohem užitečnějším je umět zařazovat správně data, u kterých skupinu, do které náleží, předem neznáme. Zde už se nejedná o klasifikaci, ale o predikci. Existuje několik metod testování síly predikce.

- Kros validace: datový soubor je náhodně rozdělen na několik podsouborů, výpočet je pak proveden na jednom podsouboru a testován u ostatních, dochází k rotaci a všechny podsoubory se postupně stanou tréninkovými a testovacími daty.

- Leave-one-out kros validace neboli Jackknife: model je tvořen za všech pozorování kromě jednoho, na kterém je testován, touto procedurou projdou všechna pozorování
- Rozdělení základního souboru na 2 podsoubory, přičemž jeden je tréninkový a druhý testovací

První 2 metody je vhodné užít při nízkém počtu pozorování. V této práci si vystačíme s poslední možností, ověření síly predikce u každého modelu proběhne pouze jednou, neboť dat máme relativně mnoho. U kompletních dat byly cca 2/3 využity k modelování a zbytek k testování. Obory a roky jsou v testovacích datech zastoupeny co nejvíce rovnoměrně, aby nedocházelo k nadržování jednotlivým kategoriím. U oborových dat bylo náhodně vybráno cca 10 % pozorování napříč lety a ta byla uschována pro testování predikce. Přehled počtu pozorování, která byla použita pro tvorbu a testování vidíme níže v Tabulce 18.

Tab. 18 Počet pozorování u odvětví určený k tvorbě a testování modelů

| Sekce NACE | Odvětví | Velikost tréninkového souboru | Velikost testovacího souboru |
|-------------------|---------------------------------------|--------------------------------------|-------------------------------------|
| A | ZEMĚDĚLSTVÍ, LESNICTVÍ A RYBÁŘSTVÍ | 6797 | 540 |
| B | DOBÝVÁNÍ A TĚŽBA | 171 | 18 |
| C | ZPRACOVATELSKÝ PRŮMYSL | (14488) 7712 | 1620 |
| D | VÝROBA A ROZV. ELEKT. PLYNU, | 369 | 36 |
| E | VODA; ODPADY A SANACE | 606 | 54 |
| F | STAVEBNICTVÍ | (3799) 2051 | 432 |
| G | VELKO A MALOOBCHOD; OPR.V. | (9382) 5028 | 1044 |
| H | DOPRAVA A SKLADOVÁNÍ | (1322) 645 | 144 |
| I | UBYTOVÁNÍ, STRAV. A POH. | 613 | 36 |
| J | INFORM. A KOMUN. ČINNOSTI | 644 | 72 |
| L | ČINN. V OBLASTI NEMOVITOSTÍ | 550 | 45 |
| M | PROF., VĚDEC. A TECHN. ČINN. | (1162) 536 | 126 |
| N | ADMINISTR.A PODP. ČINNOSTI | (481) 237 | 54 |
| A-N | CELKOVÝ MODEL napříč odvětvími | 9544 | 4221 |

Čísla v závorce udávají původní počet pozorování, který byl použit k modelování. U některých odvětví, kde by to mohlo mít pozitivní vliv, bylo na základě kategorizovaných grafů rozhodnuto o osekání dat o krajní hodnoty (dál, než 2 směrodatné odchylky) u všech proměnných za účelem dosažení lepší kvality modelu. V konečných modelech tedy figurují čísla mimo závorku. Počty firem pocházejí z průřezu 9 let, i tak lze vypočítat, že podíly na celkovém počtu firem by mohly odpovídat rozložení oborů v hospodářství, viz Tabulka 19.

Tab. 19 Rozložení oborů v národním hospodářství a ve zkoumaných datech

| Sekce NACE | Odvětví | Zastoupení v ekonomice | Zastoupení v datovém souboru |
|-------------------|---------------------------------------|-------------------------------|-------------------------------------|
| A | ZEMĚDĚLSTVÍ, LESNICTVÍ A RYBÁŘSTVÍ | 5,43 % | 16,83 % |
| B | DOBÝVÁNÍ A TĚŽBA | 0,03 % | 0,42 % |
| C | ZPRACOVATELSKÝ PRŮMYSL | 13,43 % | 35,88 % |
| D | VÝROBA A ROZV. ELEKT. PLYNU, | 0,82 % | 0,91 % |
| E | VODA; ODPADY A SANACE | 0,47 % | 1,50 % |
| F | STAVEBNICTVÍ | 14,38 % | 9,41 % |
| G | VELKO A MALOOBCHOD; OPR.V. | 28,46 % | 23,23 % |
| H | DOPRAVA A SKLADOVÁNÍ | 3,07 % | 3,27 % |
| I | UBYTOVÁNÍ, STRAV. A POH. | 6,46 % | 1,52 % |
| J | INFORM. A KOMUN. ČINNOSTI | 2,46 % | 1,59 % |
| L | ČINN. V OBLASTI NEMOVITOSTÍ | 7,23 % | 1,36 % |
| M | PROF., VĚDEC. A TECHN. ČINN. | 15,54 % | 2,88 % |
| N | ADMINISTR.A PODP. ČINNOSTI | 2,23 % | 1,19 % |
| | Celkem | 100,00 % | 100,00 % |

Zdroj: ČSÚ

Procentuální zastoupení v reálné ekonomice je upraveno o sektory, které se ve zkoumaných datech nevyskytují. Jde o cca 0,5 mil společností, zastoupení v tabulce výše je tak mírně nadhodnoceno oproti realitě. Při srovnání čísla v datech v podstatě odpovídají reálné ekonomice s výjimkou sekce M a C. Rozdíl u sekce M se dá vysvětlit filtračními kritérii při výběru dat, kdy společnosti s aktivy nižšími než 1 milion korun byly ignorovány. Stejná příčina s opačným efektem způsobila u sekce

C její nadměrné zastoupení. Dá se očekávat, že výrobní společnosti potřebují pro svou činnost v průměru aktiva ve vyšší hodnotě než společnosti poskytující služby, proto se jich velká část dostala do zkoumaných dat. Všeobecně však struktura odpovídá, u modelů si tudíž osobujeme nárok na použitelnost vztahující se k celému hospodářství.

3.5 Výsledky

V této sekci budou prozkoumány a porovnány výsledné modely. Vzhledem k tomu, že celkový počet modelů doporučených pro praktické využití je, jak uvidíme, 13, tzn. 1 pro každý obor, nebudou dopodrobna zkoumány všechny. Bude detailně rozebrán způsob tvorby modelu a testování na praktickém případě tak, jak je to popsáno v předchozí kapitole. Konkrétně se jedná o tvorbu všeoborového modelu ve 2 variantách. Se zařazením všech výše v práci zmíněných proměnných do modelování a s vypuštěním makroekonomických proměnných. Dalším krokem bude zlepšení kvality predikce pomocí specifických oborových modelů.

3.5.1 Všeobecný model

Prvotním záměrem bylo vytvořit jeden univerzální model, který by s relativně vysokou úspěšností pokryl všechna odvětví. Do modelování tedy vstupovalo 9544 pozorování, u nichž mělo 5648 pozorování kategorizující proměnnou budoucí EVA zápornou a 3896 pozorování budoucí EVA kladnou. Celkový počet nezávislých proměnných je 39, z toho 27 poměrových ukazatelů, 11 makroekonomických ukazatelů a současné EVA. Tabulka 20 zobrazuje výsledek po 5 krocích.

Tab. 20 Dialog výsledků diskriminační analýzy po 5 krocích

| Proměnná | Wilk. (Lambda) | Parc. (Lambda) | F na vyjmutí | Toler. | 1-toler. (R ²) |
|--|----------------|----------------|--------------|--------|----------------------------|
| ROE – Rentabilita vlastního kapitálu % P/L for Period [=Net income]/Shareholders Funds | 0,855 | 0,971 | 284,935 | 0,659 | 0,340 |
| CZK/EUR průměr 2005-2013 | 0,847 | 0,980 | 196,341 | 0,996 | 0,003 |
| Capital Turnover: Current Assets/Total Assets | 0,849 | 0,978 | 217,445 | 0,853 | 0,146 |
| Rentabilita tržeb % (Operating P/L [=EBIT/Operating revenue (Turnover)]) | 0,846 | 0,982 | 173,758 | 0,644 | 0,355 |
| Debt Equity ratio % (Non-Current Liabilities+Current Liabilities)/Shareholders Funds | 0,838 | 0,991 | 87,990 | 0,924 | 0,075 |

První sloupec obsahuje proměnné v pořadí, v jakém byly přidávány do modelu. Druhý sloupec ukazuje, na kolik by se zvýšilo kritérium kvality modelu, pokud bychom z něj vyřadili danou proměnnou. Vzpomeňme, že kritérium nabývá hodnot od 0 do 1 a zobrazuje podíl vnitroskupinové a celkové variability, tzn., menší hodnota indikuje lepší rozřazovací schopnost nezávislých proměnných. Kritérium kvality vidíme v další tabulce i s celkovým F-testem významnosti.

Tab. 21 Test významnosti modelu

| Wilkova lambda | Celkový F-test | Stupně volnosti | p-hodnota |
|----------------|----------------|-----------------|-----------|
| 0,83040322 | 389,6 | 5 | <0,001 |

Kritický kvantil pro $F_{0,025}(5,9538)$ je 2,56782. Testovací kritérium spadá do kritického oboru, zamítáme H_0 o nevýznamnosti. Vnitroskupinová variabilita je významně odlišná od celkové, tudíž je model schopen diskriminace.

Pro tento model nedosahuje Wilkova Lambda nízkých hodnot, dalším přidáváním proměnných bychom ji zřejmě výrazně nezlepšili, neboť už při posledním kroku se zlepšila jen o 0,008, což je zanedbatelná hodnota. Další sloupec označuje hodnoty F-testu pro vyřazení z modelu. Při zpětné metodě by byla vyřazena proměnná s nejnižší hodnotou F-testu. V našem případě by šlo o Debt Equity ratio, což

odpovídá skoro žádnému přispění ke zlepšení diskriminace jejím přidáním do modelu. Poslední 2 sloupce kontrolují pro nadbytečnost proměnných, kdy tolerance vyjadřuje míru, nakolik proměnná není vysvětlena ostatními, např. první proměnná ROE je ostatními proměnnými v modelu vysvětlena z 65,9 %. Princip je stejný jako u regresní analýzy. 1-Tolerance zobrazuje opak a je vlastně koeficientem determinace. Před modelováním je možné nastavit minimální míru tolerance, při které je možné přidat proměnné do modelu a tímto se tak dá bránit proti duplicitě informací obsažených v různých proměnných. Víme tedy, že model je významný, ačkoliv jeho diskriminační síla se nezdá být vysoká. Níže vidíme tabulku s koeficienty pro kanonickou diskriminační funkci.

Tab. 22 Prosté koeficienty, celkový model s makroekonomickými proměnnými

| Proměnné v modelu | Prosté koeficienty |
|--|--------------------|
| ROE – Rentabilita vlastního kapitálu % P/L for Period [=Net income]/Shareholders Funds | 2,92346 |
| CZK/EUR průměr 2005-2013 | 0,22124 |
| Capital Turnover: Current Assets/Total Assets | 1,56357 |
| Rentabilita tržeb % (Operating P/L [=EBIT/Operating revenue (Turnover)]) | 5,20917 |
| Debt Equity ratio % (Non-Current Liabilities+Current Liabilities)/Shareholders Funds | 0,14260 |
| Konstanta | -7,49231 |

Pokud dosadíme do kanonické diskriminační funkce hodnoty proměnných, vypočítáme tak skóre, které se porovná s v předchozím oddíle zmíněnými skupinovými centroidy a ten, který je blíže, určuje příslušnost ke skupině. Hodnoty centroidů pro tento model vidíme v Tabulce 23.

Tab. 23 Skupinové centroidy, celkový model s makroekonomickými proměnnými

| Skupiny | Skupinové centroidy |
|-------------|---------------------|
| Záporná EVA | -0,375302 |
| Kladná EVA | 0,544072 |

Z tabulky vyplývá, že vyšší skóre zařadí pozorování do skupiny kladná EVA, nízké naopak přiřadí pozorování pro příští rok záporná EVA. Než se však pustíme k samotné klasifikaci, je nutné se zamyslet nad věcným významem koeficientů kanonické diskriminační funkce.

V zásadě existují 2 způsoby, jakým způsobem se stavět k diskriminační analýze a interpretaci významných proměnných. První způsob říká, že do modelování zařazujeme ukazatele, pro které máme jasný teoretický podklad ve smyslu, jaký vliv by měly mít na modelovanou proměnnou. Příkladem může být proměnná ROE v tomto modelu. EVA je počítána pomocí ukazatele NOPAT, který je jednou

z úrovně zisku, čím vyšší zisk, tím vyšší EVA. Ukazatel ROE je také vypočítán pomocí jedné z mnoha úrovně zisku a řídí se stejným vztahem. To znamená, že čím vyšší zisk, tím vyšší ROE neboli návratnost na vlastní kapitál. Proto by EVA a ROE měly být kladně korelované veličiny ovlivňované veličinou třetí, v tomto případě ziskem. Za normálních okolností, tedy když se vše odehrává v čase 0, nemá smysl toto zkoumat, protože se jedná pouze o vzorce. V našem případě jde ale o modelování závislosti v čase. Kladné ROE v čase nula může být silným signálem o zdravé, ziskové firmě s předpokladem, že v roce příštím bude kladná EVA, což už je zajímavé. Proto je potřeba zkoumat znaménka koeficientů kanonické diskriminační funkce v kontextu znamének skupinových centroidů, zdali nejsou v rozporu s věcnými předpoklady. Pro případ s ROE se zdá být vše v pořádku, hodnota koeficientu je 2,92346, centroid pro kladnou EVA je 0,544072. Čím vyšší ROE v roce 0, tím vyšší pravděpodobnost, že pozorování bude po výpočtu celkového skóre zařazeno do skupiny s kladnou EVA. V opačném případě může neshoda s teoretickým předpokladem znamenat vážně chyby struktury dat, které ovlivňují výsledky. Model může být kvalitní, pokud jde o klasifikaci, ale jakmile bychom ho použili při predikci na jiných datech, úspěšnost bude zřejmě velmi malá.

Druhý způsob, jakým se dívat na zařazování proměnných do modelování je tzv. „Capitalizing on chance“ neboli využití náhody. U mnoha ukazatelů nemusí být očekávané znaménko jasné ať už z důvodu rozcházejících se teorií, či prosté komplikovanosti výkladu významu ukazatele. Zde je tedy těžké říci, jestli by mělo správně zvýšení ukazatele hrát ve prospěch jedné či druhé skupiny (případně více). V našem případě by se takto dalo hovořit o proměnné Debt Equity ratio. Pokud se podíváme na postup jejího výpočtu, udává poměr krátkodobého a dlouhodobého cizího kapitálu a vlastního kapitálu. Z teorie víme, že cizí kapitál je levnější, neboť vlastní kapitál předpokládá dobu návratnosti nekonečno. Ukazatel EVA je ovlivňován náklady na cizí a vlastní kapitál. EVA je tedy vyšší, pokud do firmy zapojujeme vedle vlastního kapitálu i cizí, v tom to případě je navíc zahrnut i bezplatný dodavatelský úvěr. Pokud však překročíme jistou míru (a ta je z pohledu podniků individuální), pak je podnik předlužen a náklady na cizí kapitál mohou snadno překonat náklady na vlastní kapitál. Znaménko by se tedy převrátilo. S tímto model neumí pracovat, a jak se zdá, v datech převládají firmy, které vhodně namixovaly své zdroje financování a ty teď působí pozitivně na tvorbu EVA. U takovýchto proměnných tedy naopak spoléháme na určitou strukturu, která je v datech identifikována a umožňuje od sebe skupiny úspěšně odlišovat. Nutno dodat, že v případě pokusu o replikaci i s mírně rozdílnými daty se taková struktura nemusí znovu objevit, ačkoliv i její predikční schopnosti se mohou ukázat velmi dobré.

V této práci je preferován kompromisní přístup. V případě, že je u poměrového ukazatele opačné než očekávané znaménko, pak je diskutován, zdali by nemohly nastat podmínky, kdy by taková situace byla relevantní. To vše v souvislosti s diskriminační silou zkoumaného ukazatele a také porovnáním se znaménky v jiných modelech, pokud se tam nachází. U makroekonomických proměnných je přímočařejší přístup. Pokud je zjištěn nesoulad mezi předpokladem a výsledkem,

zřejmě se jedná o chybu ve struktuře dat způsobenou extrémně nízkým množstvím pozorování (9 hodnot pro každou proměnnou) a s tím spojenou nízkou variabilitou. Protože se makroekonomické proměnné mění jen napříč roky a ne v nich, mohou se stát významnými pouze tehdy, pokud se výrazně mění poměry společností s kladným a zápornou EVA na celku v průběhu let. Nyní se tedy podíváme na znaménka ukazatelů v prvním modelu. Všechna znaménka jsou kladná, proto by měly vysoké hodnoty určovat kladnou EVA. ROE a Debt Equity ratio byly diskutovány.


Další na řadě je kurz CZK/EUR. V případě, že kurz vzroste, koruna tak oslabí a pro subjekty mající výdělků v korunách jsou nákupy v zahraničí dražší a naopak, subjekty v zahraničí dostanou za své peníze více zboží a služeb od českých společností. Proto růst kurzu působí pozitivně na ziskovost firem, což je v souladu s růstem EVA.

Pokud jde o Capital Turnover, zde kalkulovaný jako poměr oběžných aktiv a celkových aktiv, vyšší podíl oběžných aktiv znamená, že společnost je efektivní při využití fixních aktiv. Mějme nicméně na paměti, že u této veličiny může dosti záležet na odvětví. Zlepšuje výsledek u obchodních a nevýrobních společností s nízkou potřebou stálých aktiv a naopak znevýhodňuje nízkoobrátkové společnosti, které potřebují pro své fungování stroje, budovy atp. Typickým příkladem by byly velké strojírenské společnosti. Také by bylo nutno brát v potaz strukturu a likviditu oběžných aktiv. Převládající množství zásob a pohledávek může znamenat neschopnost měnit pohledávky v peníze a příliš velké množství zásob nedostatky v nákupním procesu a zbytečně vázaný kapitál. Tuto proměnnou prozatím přijmeme, jak je s tím, že budeme sledovat, jestli a jak se projeví v dalších modelech. Poslední proměnnou je Rentabilita tržeb spočítaná jako poměr EBIT a Obrátu. Jde o jeden z ukazatelů týkajících se výkonnosti podniku a logika je zde stejná jako u ROE, tudíž znaménko odpovídá. Pro všechna znaménka existuje racionální zdůvodnění. Než přijmeme model za vhodný, kvůli nesplněnému předpokladu o nezávislosti průměrů a směrodatných odchylek. Níže vidíme párové t-testy o rovnosti průměrů mezi skupinami. Testujeme hypotézu $H_0: \mu_0 = \mu_1$. Proměnné jsou označeny zkrácenými názvy.

Tab. 24 Párové t-testy o rovnosti průměrů

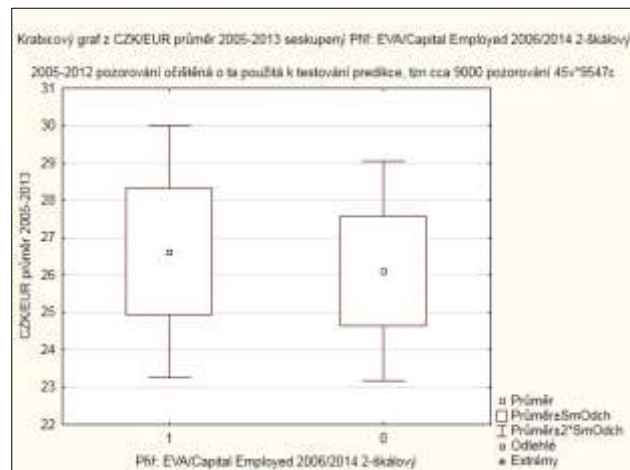
| Proměnná | Průměr (0) | Průměr (1) | t statistika | Stupně volnosti | p-hodnota |
|-------------------|------------|------------|--------------|-----------------|-----------|
| ROE | 0,07722 | 0,03798 | 24,27032 | 9542 | <0,001 |
| CZK/EUR | 0,17996 | 0,05145 | 35,41992 | 9542 | <0,001 |
| Capital Turnover | 1,98947 | 1,57429 | 11,77526 | 9542 | <0,001 |
| Rentabilita tržeb | 0,59598 | 0,48981 | 20,31231 | 9542 | <0,001 |
| Debt Equity ratio | 26,63347 | 26,11809 | 15,84975 | 9542 | <0,001 |

Kritická hodnota pro $t(9542) = 1,96021$. Všechny statistiky spadají do kritického oboru, zamítáme hypotézu o rovnosti průměrů a proměnné jsou schopny diskriminace mezi 2 skupinami. Dále se podíváme na kategorizované krabicové grafy.




Obr. 4 Krabicový graf kategorizovaný: ROE – Rentabilita vlastního kapitálu % P/L for Period [=Net income]/Shareholders Funds

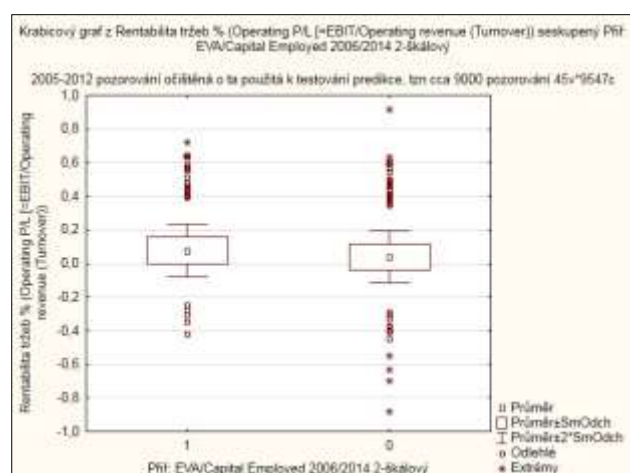
V grafu jsou vidět odlišné průměry, jejichž rovnost byla dříve vyvrácena t-testem. Zároveň je vidět, že skupiny jsou proti sobě lehce vertikálně posunuty, zejména v rozsahu intervalu jedné směrodatné odchylky. Posunutí je malé, k malé diskriminaci zřejmě bude stačit, proto dává smysl zařazení proměnné do modelu. U ostatních proměnných je situace podobná, ačkoliv ne třeba tak zřetelná. Grafy dalších proměnných budou pouze vykresleny bez komentářů, čtenář si může udělat vlastní obrázek o tom, jak moc daná proměnná přispívá k diskriminaci.



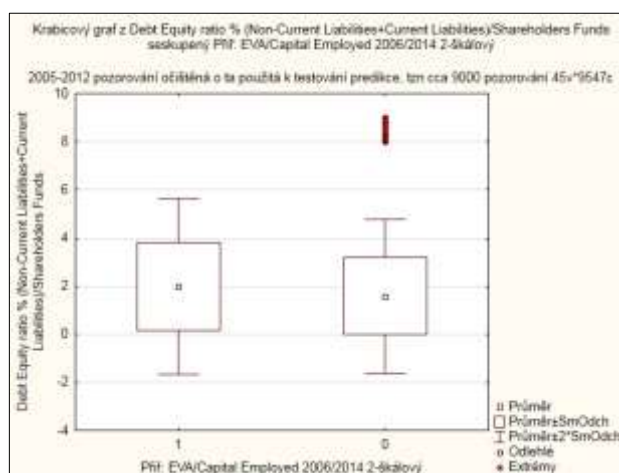
Obr. 5 Krabicový graf kategorizovaný: CZK/EUR průměr 2005-2013



Obr. 6 Krabicový graf kategorizovaný: Capital Turnover Current Assets/Total Assets



Obr. 7 Krabicový graf kategorizovaný: Rentabilita tržeb % (Operating P/L [=EBIT/Operating revenue (Turnover)])



Obr. 8 Krabicový graf kategorizovaný: Debt Equity ratio % (Non-Current Liabilities+Current Liabilities)/Shareholders Funds

U všech grafů jsou patrné rozdíly v průměrech a mírné rozdíly v hodnotách, jichž proměnné v rozdílných kategoriích nabývají. Důležité je, že to nevypadá na narušení modelu v důsledku porušení předpokladu o nezávislosti průměrů a směrodatných odchylek. Přistoupíme ke klasifikaci. Níže jsou vidět klasifikační funkce, pro každou skupinu je vytvořena jedna.

Tab. 25 Klasifikační funkce: grupovací: model s makroekonomickými proměnnými

| Proměnná | Koeficienty skupina: záporná EVA | Koeficienty skupina: kladná EVA |
|--------------------------|----------------------------------|---------------------------------|
| ROE | -11,358 | -8,671 |
| CZK/EUR průměr 2005-2013 | 10,785 | 10,988 |
| Capital Turnover | 10,337 | 11,775 |
| Rentabilita tržeb | 29,587 | 34,376 |
| Debt Equity ratio | 0,449 | 0,580 |
| Konstanta | -144,516 | -151,853 |

Po dosazení hodnot proměnných je vypočítáno klasifikační skóre a vyšší skóre určí skupinu, kam pozorování spadá. Pro ilustraci využijeme první pozorování. Názvy proměnných v tabulce jsou zkráceny, ale jedná se o tytéž proměnné jako v tabulce výše.

Tab. 26 Hodnoty prvního pozorování v datech

| Proměnná | ROE | CZK/EUR | Capital Turnover | Rentabilita tržeb | Debt Equity ratio |
|----------|--------|----------|------------------|-------------------|-------------------|
| Hodnota | 18,72% | 29,78 Kč | 0,50 | 3,92% | 188,54% |

Dosazeno do rovnice pro zápornou EVA,

$$Score_0 = -11,359 * 0,1872 + 10,785 * 29,78 + 10,337 * 0,5 + 29,587 * 0,0392 + 0,4449 * 1,8854 - 144,516 \quad (16)$$

s výsledkem 181,779. Pro skupinu s kladnou EVA platí:

$$Score_1 = -8,671 * 0,1872 + 10,988 * 29,78 + 11,775 * 0,5 + 34,376 * 0,0392 + 0,580 * 1,8854 - 151,853 \quad (17)$$

s výsledkem 182,162. Skóre pro skupinu 0 je menší, než pro skupinu 1, proto je pozorování přiřazeno jako kladná EVA. Klasifikace zde byla úspěšná, případ nabyl kladnou EVA v dalším roce i ve skutečnosti. Tímto způsobem jsou přiřazena všechna pozorování a výsledky sumarizovány pomocí klasifikační matice, viz níže.

Tab. 27 Klasifikační matice, celkový model s makroekonomickými proměnnými

| Pozorované/Předpovězené | % správně určených | Záporná EVA | Kladná EVA |
|-------------------------|--------------------|-------------|------------|
| Záporná EVA | 85,39 % | 4823 | 825 |
| Kladná EVA | 49,64 % | 1962 | 1934 |
| Celkem | 70,79 % | 6785 | 2759 |

Úspěšnost klasifikace, tzn. správné určení skupiny na datech použitých k modelování, je 70,79 %. Úspěšnost u první skupiny je výrazně vyšší než u druhé. Příčinu tohoto musíme hledat u rozdělení skupin v datech. Záporná EVA tvoří 59 % pozorování, to je výrazně více, nežli je u druhé skupiny (41 %). Model toto rozdělení zanáší do koeficientů rovnice, tzn., preferuje skupinu s vyšší četností před druhou. K završení testování slouží zkouška predikce na verifikačních datech. Testovací data se skládají ze 4221 pozorování. U každého roku jde o 469 pozorování, počet pozorování v rámci oborů je rozdílný kvůli menšímu počtu dat u některých z nich, např. u sekce B, Dobývání a těžba. Skupiny byly přiřazeny pomocí skóre spočítaného klasifikačními funkcemi. V Tabulce 28 je souhrn výsledků.

Tab. 28 Testování predikce, celkový model s makroekonomickými proměnnými

| Pozorované/Předpovězené | % správných | Záporná EVA | Kladná EVA |
|-------------------------|-------------|-------------|------------|
| Záporná EVA | 82,50 % | 1754 | 372 |
| Kladná EVA | 46,21 % | 1127 | 968 |
| Celkem | 64,49 % | 2881 | 1340 |

Celková úspěšnost predikce EVA je 64,49 %. Při bližším pohledu vidíme, že se zde opět promítají vlivy různě velkých modelovaných skupin, 0:1 zhruba 60:40. Je pochopitelné, že úspěšnost predikce je nižší než úspěšnost klasifikace. Testovací data model nikdy předtím „neviděl“. V případě, že bychom zcela náhodně určovali při-

slušnost ke skupině bez ohledu na četnosti skupin pouhým rozdělením výběru do 2 skupin, 50 % případů skončí ve správné skupině. Model prokázal, že proměnné, z nichž je sestaven, skutečně mají určitou schopnost diskriminace. Pokud se podíváme na kategorizované grafy, vidíme, že hodnoty dat ve skupinách se z velké části překrývají. Hodnota Wilkovy lambdy pro celkový model je 0,83040, což je na stupnici od 0 do 1 velmi špatný výsledek (ideální hodnota je 0). Pokud pomíneme ořezání dat o skutečně extrémní hodnoty u několika proměnných, s daty nebylo jinak manipulováno a takovýto výsledek se dal v podstatě očekávat. Druhý model byl vytvořen při vyloučení makroekonomických proměnných. Makroekonomické proměnné nebyly testovány na počáteční předpoklady.

Ačkoliv v modelu uvedený kurz CZK/EUR je kompatibilní s předpokladem znamének a test predikce na tolika pozorováních je dostatečně přesvědčivý o síle modelu, mohou přetrvávat pochybnosti ohledně spolehlivosti dané proměnné a stability vztahu vůči modelované EVA jednoduše kvůli nízkému počtu pozorování CZK/EUR. Např. při přidání 2 let do modelu by se mohla radikálně změnit struktura dat a proměnná z modelu vypadnout, což by nesvědčilo o správnosti jejího zařazení. To se u podnikových proměnných nestane, při takovém množství pozorování (tisíce), jsou méně náchylně k popsanému typu chyb. Po 5 krocích bylo dosaženo modelu níže.

Tab. 29 Prosté koeficienty, celkový model bez makroekonomických proměnných

| Proměnné v modelu | Prosté koeficienty | Prosté koeficienty-původní model |
|--|--------------------|----------------------------------|
| ROE | 3,12699 | 2,92346 |
| Capital Turnover | 1,41069 | 1,56357 |
| Rentabilita tržeb | 5,54623 | 5,20917 |
| Debt Equity ratio | 0,20845 | 0,14260 |
| Financial Leverage % (Long Term Debt+Loans)/Total Assets | -1,51372 | X |
| Konstant | -1,48255 | -7,49231 |

Wilkova lambda má hodnotu 0,84210, což je horší výsledek z jasných důvodů. Pokud by proměnná Financial Leverage byla preferovanější, než kurz CZK/EUR, vstoupila by do modelu již poprvé. Protože jsme se makroekonomických proměnných zbavili a preferujeme stejný počet kroků jako dříve, musela na místo CZK/EUR nastoupit druhá nejlepší proměnná, proto je výsledek o něco málo horší. Všechny původní proměnné zůstaly významné, stejně tak se významně nezměnily jejich koeficienty. Místo kurzu CZK/EUR přibyl ukazatel „Financial Leverage“, tady spočítán jako poměr pasiv nesoucích úrok a celkových aktiv, tzn. vyjadřující míru financování aktiv cizím kapitálem. Níže vidíme srovnání skupinových centroidů.

Tab. 30 Skupinové centroidy, celkový model bez makroekonomických proměnných

| Skupiny | Skupinové centroidy | Skupinové centroidy- původní model |
|-------------|---------------------|---------------------------------------|
| Záporná EVA | -0,359600 | -0,375302 |
| Kladná EVA | 0,521310 | 0,544072 |

Středky skupin se změnilo minimálně. Z věcného pohledu jsou všechna znaménka u původních proměnných relevantní. Ukazatel „Financial Leverage“ je na první pohled velmi podobný Debt equity ratio s tím rozdílem, že nový ukazatel se zaměřuje pouze na cizí pasiva nesoucí úrok. Orientace ukazatele pak odpovídá dříve zmíněnému problému při předložení podniku. Předložena společnost má vyšší náklady kapitál než společnost pouze s vlastním kapitálem či malým podílem cizího. Ukazatel může nabývat hodnot od 0 do 1 (všechna aktiva jsou na dluh), i relativně malý podíl zadlužených aktiv tak může vést k relativně vysokému riziku a tím pádem i úroku. Mysleme na to, že zde není počítáno o cizím neúročeném kapitálu, např. závazcích, což bývá významná položka na rozvaze společností. Je pak velký rozdíl, jestli jsou celková aktiva financována cizími pasivy z 20 %, či jestli těch 20 % tvoří pouze úročený cizí kapitál (a financování celkovými pasivy je pak např. 40 %). Proto se se znaménkem ztotožňujeme a budeme model testovat. V Tabulce 31 je klasifikační matice o něco málo horší výsledek než klasifikační matice v původním modelu.

Tab. 31 Klasifikační matice, celkový model bez makroekonomických proměnných

| Pozorované/Předpovězené | % správných | Záporná EVA | Kladná EVA |
|-------------------------|-------------|-------------|------------|
| Záporná EVA | 85,32 % | 4819 | 829 |
| Kladná EVA | 46,89 % | 2069 | 1827 |
| Celkem | 69,63 % | 6888 | 2656 |

Zajímavějším srovnáním je predikční schopnost modelu. Testování znovu probíhá na nepoužitých datech o celkovém počtu 4221 pozorování. Očekáváme horší výsledek než u původního modelu se zařazením makroekonomických proměnných.

Tab. 32 Klasifikační matice k predikci, celkový model bez makroekonomických proměnných

| Pozorované/Předpovězené | % správných | Záporná EVA | Kladná EVA |
|-------------------------|-------------|-------------|------------|
| Záporná EVA | 86,88 % | 1847 | 279 |
| Kladná EVA | 44,87 % | 1155 | 940 |
| Celkem | 66,03 % | 3002 | 1219 |

Ten se ale nepotvrdil, nový model má dokonce o více než 1% lepší predikční sílu, než model původní. Vysvětlením může být dříve zmiňovaný problém s makroekonomickými proměnnými. Proměnná CZK/EUR je pro klasifikaci úspěšná jen díky struktuře dat a již zmíněnému „zneužití náhody“. Pro kontrolu predikce se však její

síla stírá. Při pokusu o opakování práce i jen s trochu odlišnými daty bychom došli k jiným výsledkům a kurz CZK/EUR by se nestal vůbec významným. Mělo by být připomenuto, že významnost makroekonomických proměnných se zde může zakládat pouze na „struktuře“ dat, tudíž by to mělo být v pořádku, ale malý počet pozorování se zdá být hrozbou. Pro úspěšné zařazení informací o vnějším prostředí společností by tedy byla zřejmě zapotřebí delší roční časová řada nebo, ideálně, údaje na čtvrtletní bázi. Ačkoliv sehnat makroekonomická data o této frekvenci by problém nebyl, u firemních dat tomu tak není. Drtivá většina společností zveřejňuje údaje o svých finančních výkazech pouze jednou ročně s koncem svého finančního roku.

3.5.2 Oborové modely

Práce, které se zabývají podobnou problematikou predikce, prezentují své poznatky jako poplatné napříč obory. Pravdou je, že hodnoty proměnných, které jsou používány v této práci, se mohou napříč obory poměrně dosti lišit. Potřeba pracovního kapitálu u těžebních společností se odvíjí od jiných reálií, než u obchodních společností. Další dobrý příklad může být ukazatel obrát zásob, pohledávek či závazků. Modely výše jsou vytvořeny na základě dat s v podstatě velkou heterogenní strukturou. Rozdělení dat po jednotlivých oborech a vytvoření modelů nad nimi by mohlo zvýšit kvalitu predikce.

První model se týká sekce A: Zemědělství, lesnictví a rybářství. Sekce má 6797 pozorování pro tréninkový dataset a 541 jako testovací dataset. Níže jsou vidět koeficienty kanonické diskriminační proměnné.

Tab. 33 Prosté koeficienty, A, Zemědělství, lesnictví a rybářství s makroekonomickými proměnnými

| Proměnné v modelu | Prosté koeficienty |
|--|--------------------|
| EVA 2005-2013 | 0,0001 |
| Obecná míra nezaměstnanosti %, průměr 2005-2013 | 123,5665 |
| Zemědělství- tržby %, r/r, reálně 2005-2013 | -13,8571 |
| CZK/EUR průměr 2005-2013 | -0,3493 |
| Rentabilita tržeb % (Operating P/L [=EBIT/Operating revenue (Turnover)]) | 1,0663 |
| Konstanta | -7,49231 |

Skupinové centroidy pro kontrolu znamének.

Tab. 34 Skupinové centroidy, A, Zemědělství, lesnictví a rybářství s makroekonomickými proměnnými

| Skupiny. | Skupinové centroidy |
|-----------------|----------------------------|
| Záporná EVA | -0,565267 |
| Kladná EVA | 0,541334 |

Při porovnání hodnot centroidů a koeficientů v modelu dojdeme k několika nesrovnalostem. Všechny makroekonomické proměnné se chovají zcela kontra intuitivně. Dle všeho by kladná EVA měla být indikována růstem nezaměstnanosti, záporná EVA pak růstem tržeb v odvětví a oslabováním kurzu koruny. Vysvětlení, proč se jedná o nesmysly, se nabízí už jen z použitých vzorců pro výpočet EVA. NOPAT je jasným zástupcem informací o výsledcích společnosti. Pokud ty rostou, roste i NOPAT a tím EVA. V případě růstu nezaměstnanosti klesá celková ekonomická aktivita a tím spotřeba, což se negativně odráží na vývoji tržeb, koeficient však napovídá opačný průběh. U další proměnné, tržeb v zemědělství dochází při růstu v čase t k indikaci poklesu EVA v čase $t+1$. K tomu zřejmě není co dodat. Taková situace by zřejmě panovala pouze tehdy, pokud by se zemědělství řídilo hospodářským cyklem s frekvencí 1 roku. V neposlední řadě, oslabování koruny by mělo vést k lepším exportním možnostem a tržbám. Přestože je zemědělství jistě specifickým oborem, není důvodu, proč by to mělo být naopak. Navíc je dalším překvapením významné zastoupení těchto proměnných v modelu. Vše indikuje na pouhou matematickou významnost v důsledku vztahů uvnitř dat.

Proto upustíme od používání makroekonomických proměnných pro všechny zbývající modely a budeme používat jen firemní data. Pro zemědělství má pak model podobu uvedenou v Tab. 35.

Tab. 35 Prosté koeficienty, A, Zemědělství, lesnictví a rybářství bez makroekonomických proměnných

| Proměnné v modelu | Prosté koeficienty |
|--|---------------------------|
| EVA 2005-2013 | 0,000067 |
| Financial Leverage % Other Shareholders Funds/Total Assets | 1,518234 |
| Debt Equity ratio % (Non-Current Liabilities+Current Liabilities)/Shareholders Funds | 0,258658 |
| Rentabilita tržeb % (Operating P/L [=EBIT/Operating revenue (Turnover)]) | 4,717611 |
| Doba obratu zásob Stocks/((Operating revenue (Turnover))/360) | -0,004331 |
| Konstanta | -0,546545 |

Klasifikační funkce je uvedena v příloze. Test predikce viz Tab. 36.

Tab. 36 Predikce, Sekce A: Zemědělství, lesnictví a rybářství bez makroekonomických proměnných

| Pozorované/Předpovězené | % správných | Záporná EVA | Kladná EVA |
|-------------------------|-------------|-------------|------------|
| Záporná EVA | 82,22 % | 222 | 48 |
| Kladná EVA | 52,22 % | 129 | 141 |
| Celkem | 67,22 % | 351 | 189 |

Výsledek je o něco málo lepší než u celkového modelu. Jsme zřejmě na dobré cestě. Nebudeme se už zabývat do detailu konkrétními modely, nýbrž sumarizujeme četnost použití proměnných a míru úspěšnosti predikce.

Tab. 37 Tabulka četností objevení se proměnných ve 13 oborových modelech

| Proměnná | Četnost v modelech | Proměnná | Četnost v modelech |
|---|--------------------|---|--------------------|
| ROE [=Net income]/Shareholders Funds | 10 | Úrokové krytí I. Operating P/L [=EBIT/Interest Paid] | 2 |
| Debt Equity ratio | 7 | Pracovní kapitál | 2 |
| Rentabilita tržeb | 6 | Average cost of employee | 2 |
| Capital Turnover Current Assets/Total Assets | 6 | Mzdová náročnost tržeb | 1 |
| EVA 2005-2013 | 5 | Doba inkasa pohledávek | 1 |
| Shareholders funds per employee | 5 | Financial Leverage (Current Assets-Current Liabilities)/(Long Term Debt+Loans) | 1 |
| Doba obratu zásob | 3 | Financial Leverage Long Term Debt/Current Assets | 1 |
| Financial Leverage % Other Shareholders Funds/Total Assets | 3 | Cash position | 1 |
| Financial Leverage % (Long Term Debt+Loans)/Total Assets | 3 | EBITDA Margin | 1 |
| Doba úhrady krátkodobých závazků | 2 | Costs of employees / Operating revenue | 1 |

Výše je vidět, jaké proměnné a kolikrát se objevily v modelech. Nejúspěšnější v tomto smyslu se stala rentabilita vlastního kapitálu. To značí, že u společností

vládne silný trend ve výkonech. Ty, které vynášejí svým vlastníkům a investorům nad očekávanou úroveň to budou s velkou pravděpodobností dělat i v budoucnosti a je tam platnost napříč odvětvími. Další významným ukazatelem je Debt Equity ratio, což je poměr cizích a vlastní pasiv. Ve všech modelech vyšší hodnota predikuje tvorbu kladné EVA. Důvodem je zde zřejmě nepříliš vysoká zadluženost českých podniků v kombinaci s tvorbou kladné EVA. Z toho vyplývá v průměru dobrý poměr cizích a vlastních pasiv, tzn., snižuje náklady na financování a zároveň není likvidační. Četnost ukazatele rentabilita tržeb (počítané jako EBIT/obrat) má podobné odůvodnění jako ROE, ačkoliv se ukazatel skládá z odlišných proměnných. Schopnost generovat vysoký zisk v poměru k celkovým tržbám se dá obecně spojit s marží. Čím vyšší marži je schopna si firma udržet, tím spíše bude mít vyšší zisk a tím i EVA. Další proměnná, poměr oběžných a celkových aktiv, se ukázala významná téměř v polovině modelů. 3 z nich jsou kapitálově náročná odvětví a to dobývání a těžba, zpracovatelský průmysl a výroba rozvod elektřiny a plynu. Vysoký poměr oběžných aktiv na celkových v těchto odvětvích značí efektivní využití fixního kapitálu při daných výnosech. Nutno dodat, bylo by dobré prozkoumat strukturu a stáří těchto aktiv. Je určitě pozitivní, pokud má podnik oběžná aktiva vázaná v penězích (i ty každopádně potřeba investovat), než pokud má velké množství stárnoucích pohledávek nebo nadbytečné množství zásob materiálu či hotových výrobků. Ukazatel EVA 2005-2013, tzn. EVA v čas nula, kterou již známe, jen znovu dokládá sílu trendu generovat či negenerovat ekonomickou přidanou hodnotu. Poslední proměnnou s velkou četností je vlastní kapitál na zaměstnance. Ve všech modelech více kapitálu predikuje zápornou EVA. Chování je konzistentní napříč modely, tudíž by mělo mít věcné vysvětlení. Klasické vysvětlení spočívá v efektivitě využitého kapitálu, kdy vyšší kapitál na zaměstnance znamená lepší zapojení zdrojů při nižších nákladech na zaměstnance. Takováto úvaha je relevantní, pokud bychom zkoumali poměr celkového kapitálu na zaměstnance. Zkoumaným zde je však vlastní kapitál a jak bylo výše v práci řečeno, jeho cena je vyšší nežli u cizího. Vysoký poměr vlastního kapitálu na zaměstnance indikuje i vyšší podíl vlastního kapitálu na celkovém kapitálu, tudíž drahé financování. Nižší ukazatel naopak předpokládá menší poměr vlastního a celkového kapitálu, tzn. nižší náklady a vyšší EVA.

Nyní se dostáváme k tomu, proč jsme namodelovali 13 dalších modelů a ne pouze 1, který by byl přijatelný. Naše hypotéza říká, že model vytvořený na datech ze všech oborů obsahuje ne tak jasnou strukturu dat schopnou efektivní predikce na rozdíl od modelu, který by byl vytvořen pouze pro data z jednoho oboru. Důvodem je značná odlišnost odvětví, s ní spojený rozdílný význam položek na rozvaze i ve výsledovce a tím pádem i poměrových ukazatelů. Rozdělením oborově heterogenních dat na homogenní celky by mělo dojít ke zlepšení kvality modelu. Celkem byla testována predikce na 4221 pozorováních. Níže je vidět klasifikační matice pro testování predikce.

Tab. 38 Klasifikační matice: průměrné hodnoty predikce: 13 oborových modelů

| Pozorované/Předpovězené | % správných | Záporná EVA | Kladná EVA |
|--------------------------------|--------------------|--------------------|-------------------|
| Záporná EVA | 69,80 % | 3067 | 413 |
| Kladná EVA | 76,63 % | 4221 | 1354 |
| Celkem | 72,66 % | 3067 | 1767 |

Původní model napříč všemi odvětvími dokázal správně predikovat 66,03 % společností. Rozdělením dat do více homogenních celků jsme docílili výrazně lepší schopnosti predikce, konkrétně o 6,63 procentních bodů. Nejhorší individuální výsledek byl u sektoru dobývání a těžba, model byl vytvořen na pouhých 171 pozorováních a testován na 18. Společností v oboru v České republice je velmi málo. Díky tomu bereme výsledek za směrodatný, ačkoliv by se mohl radikálně měnit při zařazení více pozorování. Na druhou stranu byl obor zpracovatelský průmysl modelován s použitím 7712 pozorování a testován na 1620 pozorováních. Úspěšnost predikce je 73,7 %. Výsledek napříč lety a při takovém množství pozorování považujeme za velmi robustní. Při testování využitím dat z jiného časového okna než bylo 2005-2013 se dá očekávat velmi podobná úspěšnost.

4 Diskuze

Výzkum ekonomické přidané hodnoty jako ukazatele výkonnosti společností se stal od počátku 90. let populárním tématem. Stejně tak populární, ačkoliv nesrovnatelně delší dobu, jsou pokusy o predikci bonity podniků, s níž tvorba EVA úzce souvisí. V prvním případě je motivací honba za co nejlepším ukazatelem úspěšnosti podniku, ve druhém jde o zajištění nástrojů credit skoringu použitelných pro banky, případně další stakeholdery navázané na byznys dané společnosti.

Účelem práce bylo vytvořit soustavu matematických modelů, které, budou schopny s relativně dobrou pravděpodobností určit v čase t , zdali společnosti budou tvořit ekonomickou přidanou hodnotu v čase $t+1$. Byla použita metoda více-rozměrné diskriminační analýzy, která je populární v literatuře zabývající se predikcí bonity podniků, viz (Altman, 1968, Altman a Eisenbeis, 1978, Taffler 1984 atd.). Metoda je poměrně jednoduchá a má snadno interpretovatelné výsledky, zřejmě proto je tak populární. Každá metoda s sebou však nese potenciaální problémy. Shrnuje je Vochozka (2011), první relevantní výhradou je kritika metodiky výběru dat, kdy data bývají často vybrána nenáhodně a vykazují závadějící tendence. U modelu napříč odvětvími máme celkem 13 619 pozorování napříč lety i obory. V rámci 13 oborových modelů je celkem 25 959 pozorování. Pro srovnání Altman (1968) použil pro svůj model 66 pozorování, z toho 33 bylo bonitních a 33 ne. Chen a Dodd (1997) při zkoumání rozdílů mezi EVA a klasickými ukazateli při vysvětlování návratnosti akcií využili 1000 pozorování. Naše data by tedy neměla být negativně ovlivněna díky dostatečně velkému rozsahu. Rozdělení četnosti oborů odpovídá rozdělení četností v reálné ekonomice s výjimkou sekcí C a M, což je způsobeno ořezáním dat před stažením z databáze o společnosti s menšími aktivy než je milion Kč. Obecným doporučením je vyšší množství pozorování, neboť malá datová základna bude náchylnější na systematické chyby v datech z důvodů jejich snadnějšího narušení, například kvůli pozorováním se vzdálenými hodnotami. Další výtkou je změna vztahů korelační struktury proměnných v čase, Keasey a Watson (1991) tvrdí, že modely použité dlouhou dobu po modelování jsou již neplatné. V této práci bohužel nebyly modely testovány na datech mimo časový rámec vytvoření modelu a to z důvodu nedostupnosti novějších dat. Ačkoliv časové období pokrývalo roky 2005 až 2013, tedy krizi i konjunkturu, je možné, že se situace výrazně změnila a modely by bylo potřeba zkusit v různých okamžicích a koeficienty, případně proměnné poté zaktualizovat. Příkladem budiž index IN5 (Neumaierová, 2005), který vznikl na základě Indexu IN01 aktualizováním koeficientů.

Relevantním diskutovaným problémem je otázka zdroje dat, což jsou dokumenty účetní závěrky. Obavy jsou zejména z důvodů potenciální podvodné činnosti managementu, nepřesnosti dat a chyb ve výkazech. Pro výpočet EVA zde ještě zmiňme nutné úpravy podle Younga (1997). Jedná se o úpravu zisku o změnu stavu rezerv a zahrnutí goodwillu, hodnoty operačního leasingu a nákladů na výzkum a vývoj v příslušné výši do kapitálu (i s dopadem na výsledovku, pokud je nově). Zdrojová data bohužel neumožňovala zpracovávat takovýto detail, proto k úpravám nedošlo. Stejně tak nebyl ani k dispozici samotný NOPAT používaný

k výpočtu EVA, ale v dokumentech MPO (2016) k finanční analýze podnikové sféry se uvádí možnost využití ukazatele EBIT, který byl tedy použit. Pokud jde o další výtku a to výběr nezávislých proměnných, především poměrových ukazatelů, veškeré poměrové ukazatele byly vybrány na základě literatury o nejčastěji používaných (Kislingerová a Hnilica, 2008) či záměrně vykrývajících co nejvíce činností společnosti (Chen & Shimerda, 1981). Vochozka vnímá opakované využití těchto stejných proměnných napříč modely za zkreslující. Využití informací z finančního účetnictví je zřejmě nejspolehlivějším a přes všechny možné potíže nejobektivnějším způsobem, jak získat srovnatelná data k analýze napříč všemi společnostmi. Kromě výše zmíněných zdrojů pocházejí vybrané ukazatele z databáze Amadeus.

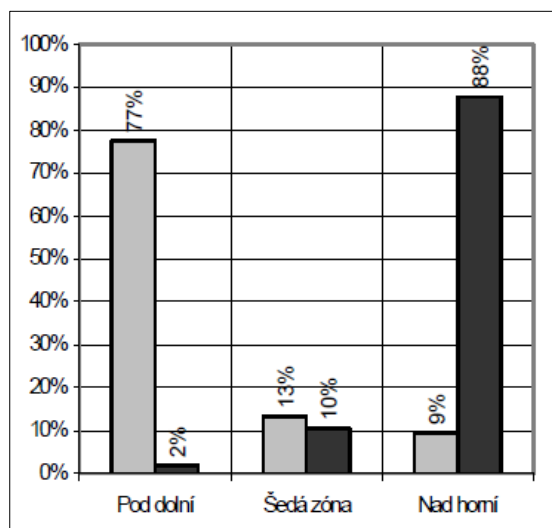
Posledním problémem, nad kterým se Vochozka zamýšlí, už v podstatě podruhé, ale z jiného pohledu, je následující otázka: Tvrdí, že díky nestabilním vztahům mezi proměnnými v čase nelze spoléhat na přesnou predikci a proto model pouze ukazuje míru podobnosti zkoumaného pozorování a skupiny. To se děje, ale o to v podstatě jde. Využití diskriminační analýzy je přímo založeno na přiřazování neznámých pozorování do skupin na základě podobnosti skupinových charakteristik daného případu. Konečná úspěšnost modelu by měla být určena na dostatečně velkém testovacím vzorku pozorování nepoužitých k modelování. Aby se předešlo spekulacím o nestálé korelační struktuře proměnných v čase, případně jejím negativním vlivu na výsledky, model by měl být testován na datech, která jsou navíc mimo časové okno, kdy byl vytvořen. Jde určitě o jednu z cest, jakým v budoucnu lépe určit kvalitu modelů.

Statistické Předpoklady modelu nejsou splněny, nicméně z důvodu značného množství dat nebudeme porušení pokládat za fatální. Porušení předpokladu o více-rozměrném normálním rozdělení nebývá považováno za fatální (Statsoft, 2016). Na druhou stranu Eisenbeis (1977) kupříkladu tvrdí, že absence normálního rozdělení může vést ke zkreslení významnosti testů. Někteří autoři narovnávají rozdělení pomocí transformací proměnných (Taffler, 1983). Předpoklad o shodných kovariantních maticích rovněž nebyl splněn, Statsoft (2016) uvádí, že při vyšším počtu pozorování by toto nemělo mít negativní vliv. Posledním testovaným předpokladem byla nezávislost průměrů a směrodatných odchylek u proměnných. V případě korelace by mohlo docházet při modelování ke zdánlivé diskriminaci a zařazování nepatřičných proměnných do modelu. Korelace byla nalezena. Pomocí testu o rovnosti skupinových průměrů, kdy tato hypotéza byla zamítnuta, jsme prokázali, že má smysl modelovat. Za účelem zbavení se podezření na negativní vliv velmi odlehklých hodnot, byly využity krabicové grafy zobrazující variabilitu skupin a jejich středy. Pokud by tomu tak bylo, je nutné proměnnou vyřadit z modelování jako nevhodnou či ji těchto hodnot zbavit.

Výše popsaných nedostatků se při modelování reálných dat prakticky nejde zbavit. Je dobré na ně poukázat, ale konečné slovo, zdali je model užitečný, by mělo být vyřčeno na základě výsledku testování na datech nevyužitých k modelování.

Ukázalo se, že využití makroekonomických proměnných jako prediktorů v diskriminační analýze v podobě, v jaké jsou zde, není ideální. Při použití ročních dat je k dispozici velmi malý počet pozorování a výsledek je velmi nestálý. Jejich

význam je totiž čistě navázán na strukturu dat, v tomto případě poměr kladné a záporné EVA v následujícím roce. Proměnné pak vykazují koeficienty s těžko interpretovatelnými znaménky. Jakubík (2007) využil pro svůj model čtvrtletní data. To by mohlo být částečným řešením za předpokladu, že by bylo ošetřeno, jakým způsobem se postavit k poměrovým ukazatelům. Veřejně dostupné informace z účetních závěrek jsou běžně na roční bázi. I kdyby bylo možné data na čtvrtletní bázi získat, nutno říci, že v průběhu fiskálního roku se na rozvaze může objevovat mnoho nepřesných informací ovlivňujících výsledek hospodaření, jako jsou například dohadné položky. Dalším důležitým parametrem je zpoždění. Bruneau a kol. (2012) využili pro svůj logit model 2 a 3 leté zpoždění proměnných. Působení různých faktorů z vnějšího prostředí společností na ně je úzce navázáno na ekonomický cyklus. V případě tvorby jednotného modelu pro všechna odvětví může být každé nastavení problematické z důvodu heterogenity dat, kdy cyklická a anticyklická odvětví budou ukazovat nekonzistentní výsledky a výsledky nebudou aplikovatelné ani na jednu skupinu. Rozdělením dat na odvětví tak, jako v této práci, může pomoci. Otázkou k řešení potom je, jakým způsobem k tomu kterému období navázat makroekonomické proměnné. Již zmiňovaná rozdílnost dat napříč odvětvími byla zkoumána a projevila se významným zlepšením celkového výsledku při rozdělení dat podle odvětvového klíče. Celkové procento správné predikce na testovacích datech, tj. 4221 pozorováních, u odvětvových modelů je 72,66 %. Úspěšnost predikce pro model společný všem odvětvím testovaná na totožných datech byla 66,03 %. Srovnání se nabízí s modelem IN05 Neumaierové (2005) Ten dělí predikci tvorby EVA do 3. intervalů jako podniky tvořící hodnotu, podniky v tzv. šedé zóně, u kterých zařazení není jasné a podniky netvořící hodnotu, viz Obrázek č. 9.



Obr. 9 Úspěšnost klasifikace případů IN05
Zdroj: Neumaierová, 2005.

Pro krajní intervaly je úspěšnost predikce relativně vysoká, 77 % u společností netvořících hodnotu a 88 % u společností tvořících hodnotu. V případě šedé zóny

je úspěšnost z pochopitelných důvodů tristní. Celková kvalita modelu nelze posoudit, neboť neznáme počet pozorování ve skupinách. Zajímavé srovnání ještě nabízí podoba modelu a využití rozdílných proměnných. IN05 má podobu

$$IN05 = 0,13 * \frac{Aktiva}{Cizí zdroje} + 0,04 * \frac{EBIT}{Nákladové úroky} + 3,97 * \frac{EBIT}{Aktiva} + 0,21 * \frac{Výnosy}{Aktiva} + 0,09 * \frac{Oběžná aktiva}{Krátkodobé závazky + Krát.bank.úvěry} \quad (18)$$

Nejvýznamnější proměnnou je rentabilita aktiv na úrovni tvorby hodnoty pro všechny účastníky (EBIT/aktiva) s nejvyšším koeficientem 3,97, hned za ní je rentabilita aktiv s využitím výnosů. Nejvíce obsaženou proměnnou v modelech zde je rentabilita vlastního kapitálu. To potvrzuje domněnku, že výkonnost podniku v současnosti je významným ukazatelem budoucího vývoje. Při pohledu na proměnné obsažené v modelu IN05 nás však musí napadat, zdali model netrpí problémy se silně vzájemně závislými prediktory. Na 3. místě je podíl aktiv a cizích zdrojů. Zapojení cizích zdrojů zde působí opačným směrem než u modelů v této práci. Čím více cizích zdrojů, tím nižší EVA. Přitom, cizí kapitál je levnější, nežli vlastní. Nezbývá než se domnívat, že u této proměnné záleží na aktuální skladbě tréninkových dat. Jedná se o problém metody, kdy vícerozměrné statistické metody nemají jak zobrazovat otočení znaménka za určitých, navíc předem neznámých podmínek. Jistým řešením by mohlo být použití dummy proměnných, pokud bychom tyto podmínky předem specifikovali. Poslední ukazatele se vztahují ke generování zisku na pokrytí úroku a k likviditě. Pro oborové modely konstruované v této práci se tyto proměnné zdají nezajímavé a málo diskriminující.

Pokud jde o využití soustavy modelů z této práce, nabízí se jich několik. V případě, že přijmeme tvrzení O'Byrne (1996) a pánů Chen a Dodd (2001) o významném spojení EVA s kapitálovým trhem, pak je možné model využít ke zlepšení odhadu, jakým způsobem investovat krátkodobě prostředky. Klasický investiční horizont u akcií je delší než jeden rok, nicméně záleží na strategii každého jednotlivého investora. Při úspěšnosti predikce 72,66 % lze hovořit o relativně dobrém vodítku budoucího vývoje společností. Zajímavé by bylo pokusit se co nejlépe zachytit také míru tvorby EVA, tzn., jak moc velkou přidanou hodnotu dle očekávání daná společnost vytvoří či naopak. Další možností využití je spojení modelů s problematikou insolvence. Společnosti produkující zápornou EVA přes určitou, individuální, mez, se budou řadit mezi podniky ohrožené na existenci. Porovnáním s množstvím bankrotů v daných kategoriích tak, jak to udělala Neumaierová (2005), bychom mohli odhalit, jaká míra destrukce kapitálu a v jakém časovém horizontu se zdá být kritická pro existenci podniku.

5 Závěr

Cílem práce bylo nalézt matematický model, který by byl schopen pomocí vhodně zvolených prediktorů určit tvorbu ekonomické přidané hodnoty (EVA). Práce je specifikována pro české společnosti. Základní data jsou údaje z výkazů účetní závěrky, tedy rozvahy, výsledovky, případně výkazu o cashflow a k nim spočítané poměrové ukazatele. Množství proměnných vstupujících do modelování bylo sníženo pomocí korelační matice a faktorové analýzy více než o polovinu na 27. Kromě vnitropodnikového prostředí zastoupeného poměrovými ukazateli byly zařazeny makroekonomické proměnné. Dále byly ověřeny předpoklady modelů. Předpoklad o vícerozměrné normalitě nebyl splněn, což není považováno za kritické. Předpoklad o shodných kovariantních maticích napříč skupinami byl vyvrácen. Skutečný dopad porušení tohoto předpokladu, pokud jestli, by byl vidět až při testování neznámých dat mimo časové okno, v němž by model vytvořen. Předpoklad o nezávislosti středních hodnot a směrodatných odchylek v celém souboru nebyl naplněn. Později byly zkoumány krabicové kategorizované grafy, zdali se proměnné v modelu skutečně vyplatí pro klasifikaci, či ne. Modely byly vytvořeny prostřednictvím vícerozměrné diskriminační analýzy, což je relativně populární metoda zpracování dat za účelem klasifikace. Jako první byl na o extrémy ořezaných 9544 pozorováních vytvořen model zahrnující data všech oborů s úspěšností predikce 64,49 %. Kvůli zjištění možné nestability koeficientů u makroekonomických proměnných byl vytvořen model na 13619 pozorováních pouze s podnikovými proměnnými. Znaménka byla konzistentní s předpoklady, model byl přijat a otestován na 4221 pozorováních s úspěšností 66,03 %.

Z důvodů značné heterogenity dat bylo uvažováno o zařazení všech oborů do jednoho modelu jako o významném omezení tohoto modelu z pohledu úspěšnosti predikce. Proto byly jednotlivé obory vyčleněny a bylo pro ně vytvořeno 13 nových modelů. Úspěšnost predikce byla testována pro každý obor zvlášť, jednalo se o stejná testovací data jako dříve. Průměrná úspěšnost modelů rozdělených po oborech byla 72,66 %. Nejčastěji se objevující proměnnou jako prediktorem byla Rentabilita vlastního kapitálu. Nachází se v 10 modelech z 13. Druhým nejčtenějším ukazatelem je poměr cizího úročeného a vlastního kapitálu. V literatuře byl nalezen model IN05 řešící velmi podobnou situaci operující již od počátku pouze na podnikových datech. Mezi ním a skupinou modelů v této práci existují shody i rozpory, co se týče prediktorů. Pokud jde o úspěšnost predikce, ta bohužel, nemohla být u modelu IN05 plně určena kvůli chybějícím informacím.

Finální soustava modelů, jež se prokázala jako lepší nežli model hromadný, může být využita jako vodítko k budoucímu vývoji EVA a s ním spojeným investičním či manažerským rozhodováním. Ukazatel EVA si stále zaslouží pozornost investorů, vlastníků a majitelů kapitálu a to do doby, dokud nebude vymyšlen nový, lepší hodnotový ukazatel, který bude plně, možná i s pomocí kvalitativních parametrů ukazovat kvalitu a potenciál společností.

6 Literatura

Kněžní zdroje

- ALTMAN, E., 1968. *Financial ratios, discriminant analysis and the prediction of corporate Bankruptcy*. Journal of Finance. Vol. 23, No. 4, pp. 589-609
- ALTMAN, E. I., EISENBEIS, R. A., 1978. *Financial applications of discriminant analysis: A clarification*. Journal of Financial and Quantitative Analysis. Vol. 13, No. 1, pp. 185-195.
- ALTMAN, E. I., HALDEMAN, R. G., NARAYANAN, P., 1977. *ZETA analysis: A new model to identify bankruptcy risk of corporations*. Journal of Banking and Finance. Vol. 1, No. 1, pp. 29-54.
- BIDDLE, C. G., BOWEN, M. R., 1999. *Evidence on EVA*. Journal of Applied Corporate Finance. Vol. 12, Issue 2, pp. 69-79.
- BRUNEAU, C., DE BANDT, O., EL AMRI, W., 2012. *Macroeconomic fluctuations and corporate financial fragility*. Journal of Financial Stability. Vol. 8, Issue 4, pp. 219-235.
- CHEN, S., DODD, L. J., 1997. *Economic Value Added (EVA™): An Empirical Examination Of A New Corporate Performance Measure*. Journal of Managerial Issues. Vol. 9, No. 3, pp. 318-333.
- CHEN, S., DODD, L. J., 2001. *Operating Income, residual income and EVATM: Which metric is more value relevant?* Journal of Managerial Issues. Vol. 13, No. 1, pp. 65-86.
- CHEN, H. K., SHIMERDA, A. T., 1981. *An Empirical Analysis of Useful Financial Ratios*. Financial Management. Vol. 10, No. 1, pp. 51-60.
- COSTIGAN, L. M., LOVATA, M. L., 2002. *Empirical analysis of adopters of economic value added*. Management Accounting Research. Vol. 13, pp. 215-228.
- EISENBEIS, R. A., 1977. *Pitfalls in the application of discriminant analysis in business, finance and economics*. Journal of Finance. June 1977, Vol. 32, No. 3, pp. 875-900.
- HEBÁK, P. A KOL., 2007. *Vícerozměrné statistické metody (1)*. Praha: Informatorium. 256 s. ISBN 978-80-7333-056-9.
- JAKUBÍK, P., 2007. *Macroeconomic Environment and Credit Risk*. Finance a úvěr- Czech Journal of Economics and Finance. Vol. 57, Issue 1-2, pp. 60-78.
- KEASEY, K., WATSON, R., 1991. *Financial Distress Prediction Models: A review of their Usefulness*. British Journal of Management. Vol. 2, Issues 2, pp. 89-102.
- KISLINGEROVÁ, E., 2010. *Manažerské finance*. 3. vyd. Praha: C. H. Beck, xxxviii, 811 s. Beckova edice ekonomie. ISBN 978-80-7400-194-9.
- KISLINGEROVÁ, E., HNILICA J., 2008. *Finanční analýza: krok za krokem*. 2. vyd. Praha: C. H. Beck, xiii, 135 s. C. H. Beck pro praxi. ISBN 978-80-7179-713-5.

- MOURITSEN, J., 1998. *Driving growth: Economic Value Added versus Intellectual Capital*. Management Accounting Research. Vol. 9, Issue 4, pp. 461-482.
- NEUMAIEROVÁ, I., 2011. Index IN05. In: *Evropské finanční systémy: sborník příspěvků z mezinárodní vědecké konference*. Brno: Masarykova univerzita, s. 143-148. ISBN 80-210-3753-P
- O'BYRNE, F. S., 1996. *EVA® and market value*. Journal of Applied Corporate Finance. Vol. 9, No. 1, pp 116-125.
- SIEGEL, E., 2014. *Kdo klikne, koupí, lže nebo zemře: síla předpovědí pomocí prediktivní analytiky*. Brno: BizBooks, 2014. ISBN 978-80-265-0168-8.
- TAFFLER, R. J., 1982. *Forecasting company failure in the UK using discriminant analysis and financial ratio data*. Journal of the Royal Statistical Society. 1982, Vol. 145, No. 3, pp. 342-358.
- TAFFLER, R. J., 1983. *The assesment of company solvency and performance using a statistical model*. Accounting and Business Research. Vol 15, No. 52, pp. 295-307.
- TAFFLER, R. J., 1984. *Empirical models for the monitoring of UK corporations*. Journal of Banking and Finance. Vol. 8, Issue 2, pp. 199-227.
- VANÍČEK, R., 2011. *Zlatá pravidla financování a tvorba diskriminační funkce*. Brno, Diplomová práce. Masarykova Univerzita, Ekonomicko-správní fakulta
- VIROLAINEN, K., 2004. *Macro stress testing with a macroeconomic credit risk model for Finland*. Helsinki: Suomen Pankki, ISBN 95-246-2155-X.
- VOCHOZKA, M., 2011. *Metody komplexního hodnocení podniku*. 1. vyd. Praha: Grada Publishing, Finanční řízení. ISBN 978-80-247-3647-1.
- YOUNG, D., 1997. *Economic value added: A primer for European managers*. European Management Journal. Vol. 15, Issue 4, pp 335-343.
- ZMIJEWSKI, M. E., 1984. *Methodological issues related to the estimation of financial distress prediction models*. Journal of Accounting Research. Supplement to Vol. 22, pp. 59-82.

Elektronické zdroje

- Analytické materiály a statistiky. *Ministerstvo Průmyslu a Obchodu* [online]. Praha: Ministerstvo Průmyslu a Obchodu, 2016 [cit. 2016-05-19]. Dostupné z: <http://www.mpo.cz/cz/ministr-a-ministerstvo/analyticke-materialy/#category238>
- Facebook's WhatsApp acquisition now has price tag of \$22 billion. *REUTERS* [online]. 2014, [cit. 2016-05-19]. Dostupné z: <http://www.reuters.com/article/us-facebook-whatsapp-idUSKCN0HV1Q820141006>
- Hlavní makroekonomické ukazatele. *Český statistický úřad* [online]. Praha: Český statistický úřad, 2016a [cit. 2016-05-19]. Dostupné z: https://www.czso.cz/csu/czso/hmu_cr
- Organizační statistika. *Český statistický úřad* [online]. Praha: Český statistický úřad, 2016b [cit. 2016-05-19]. Dostupné z: https://www.czso.cz/csu/czso/organizacni_statistika
- Statsoft: Electronic statistics texbook. *statsoft.com* [online] Tulsa: 2016 [cit 2016-05-19]. Dostupné z: <http://www.statsoft.com/Textbook/Principal-Components-Factor-Analysis>
- Tesla Announces Pricing of Initial Public Offering. *Tesla Motors, Inc.* [online]. PALO ALTO: Tesla Motors, Inc., 2010 [cit. 2016-05-19]. Dostupné z: <http://ir.teslamotors.com/releasedetail.cfm?releaseid=483517>

Přílohy

A Seznam zkratek rozvahových a výsledkových položek

Seznam zkratek použitých pro výpočet poměrových ukazatelů

- AKT – Aktiva
- CZ – Celkové závazky
- CF – Cashflow
- ČZ – Čistý zisk
- DZ – Dlouhodobý zdroje
- EBIT – Zisk před zdaněním a úroky
- FM – Finanční majetek
- KD – Krátkodobé závazky
- KrP – Krátkodobé pohledávky
- OAKT – Oběžná aktiva
- OP – Časové rozlišení
- T – Tržby
- VK – Vlastní kapitál
- Z – Účetní zisk

B Seznam všech poměrových ukazatelů

Tab. 39 Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 1. část

| Ukazatel | Výpočet | Zdroj |
|---|--|--------------|
| ROA rentabilita celkových aktiv (%) | (Operating P/L [=EBIT/Total Assets]) | Kislingerová |
| Rentabilita tržeb (%) | (Operating P/L [=EBIT/Operating revenue (Turnover)]) | Kislingerová |
| ROCE (%) | (Operating P/L [=EBIT/(Shareholders Funds+Non-Current Liabilities)]) | Kislingerová |
| ROE (%) | P/L for Period [=Net income]/Shareholders Funds | Kislingerová |
| Rentabilita tržeb (%) | P/L for Period [=Net income]/Operating revenue (Turnover) | Kislingerová |
| Finanční páka | Total Assets/Shareholders Funds | Kislingerová |
| Rentabilita vlastních finančních zdrojů (%) | Cash Flow/Shareholders Funds | Kislingerová |
| Mzdová náročnost tržeb (%) | Cost of Employees/Operating revenue (Turnover) | Kislingerová |
| Obrat aktiv Operating revenue (x) | (Turnover)/Total Assets | Kislingerová |
| Doba obratu aktiv (dny) | Total Assets/(Operating revenue (Turnover)/360) | Kislingerová |
| Doba obratu zásob (dny) | Stocks/((Operating revenue (Turnover)/360) | Kislingerová |
| Doba inkasa pohledávek (dny) | Debtors/(Operating revenue (Turnover)/360) | Kislingerová |
| Doba úhrady krátkodobých závazků (dny) | Current Liabilities/(Operating revenue (Turnover)/360) | Kislingerová |

Tab. 40 Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 2. část

| Ukazatel | Výpočet | Zdroj |
|--------------------------------|---|-----------------|
| Debt Ratio I. (%) | $(\text{Non-Current Liabilities} + \text{Current Liabilities}) / \text{Total Assets}$ | Kislingerová |
| Debt Equity ratio (%) | $(\text{Non-Current Liabilities} + \text{Current Liabilities}) / \text{Shareholders Funds}$ | Kislingerová |
| Úrokové krytí I. (x) | $\text{Operating P/L} [= \text{EBIT} / \text{Interest Paid}]$ | Kislingerová |
| Úrokové krytí II. (x) | $(\text{Operating P/L} [= \text{EBIT} + \text{Depreciation \& Amortization}] / \text{Interest Paid})$ | Kislingerová |
| Pracovní kapitál (Kč) | $\text{Current Assets} - \text{Current Liabilities}$ | Kislingerová |
| Pracovní kapitál na aktiva (%) | $(\text{Current Assets} - \text{Current Liabilities}) / \text{Total Assets}$ | Kislingerová |
| Ukazatele kapitalizace (x) | $\text{Fixed Assets} / (\text{Shareholders Funds} + \text{Non-Current Liabilities})$ | Kislingerová |
| Běžná likvidita (x) | $\text{Current Assets} / \text{Current Liabilities}$ | Kislingerová |
| Rychlá likvidita (x) | $(\text{Debtors} + \text{Cash and Cash Equivalent}) / \text{Current Liabilities}$ | Kislingerová |
| Peněžní likvidita (x) | $\text{Cash and Cash Equivalent} / \text{Current Liabilities}$ | Kislingerová |
| Return on Investment (%) | $\text{P/L for Period} [= \text{Net income}] / (\text{Total Assets} - \text{Non-Current Liabilities} - \text{Current Liabilities})$ | Chen a Shimerda |
| Capital Turnover (x) | $\text{Current Assets} / \text{Total Assets}$ | Chen a Shimerda |
| Financial Leverage (x) | $(\text{Current Assets} - \text{Current Liabilities}) / (\text{Long Term Debt} + \text{Loans})$ | Chen a Shimerda |
| Financial Leverage (x) | $\text{Long Term Debt} / \text{Current Assets}$ | Chen a Shimerda |

Tab. 41 Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 3. část

| Ukazatel | Výpočet | Zdroj |
|-----------------------------------|--|-----------------|
| Financial Leverage (%) | Long Term Debt/Total Assets | Chen a Shimerda |
| Financial Leverage (%) | Other Shareholders Funds/Total Assets | Chen a Shimerda |
| Financial Leverage (%) | (Long Term Debt+Loans)/Total Assets | Chen a Shimerda |
| Cash position (%) | Cash and Cash Equivalent/Operating revenue (Turnover) | Chen a Shimerda |
| Receivable Turnover (x) | Debtors/Stocks | Chen a Shimerda |
| Receivable Turnover (x) | (Cash and Cash Equivalent+Debtors)/Stocks | Chen a Shimerda |
| ROE using P/L before tax (%) | (Profit before tax / Shareholders funds) * 100 | Amadeus |
| ROCE using P/L before tax (%) | (Profit before tax + Interest paid) / (Shareholders funds + Non current liabilities) * 100 | Amadeus |
| ROA using P/L before tax (%) | (Profit before tax / Total assets) * 100 | Amadeus |
| ROE using Net income (%) | (Net income / Shareholder funds) * 100 | Amadeus |
| ROCE using Net income (%) | (Net income + Interest paid) / (Shareholder funds + Non current liabilities) * 100 | Amadeus |
| ROA using Net income (%) | (Net income / Total Assets) * 100 | Amadeus |
| Profit margin (%) | (Profit before tax / Operating revenue) * 100 | Amadeus |
| EBITDA margin (%) | (EBITDA / Operating revenue) * 100 | Amadeus |
| EBIT margin (%) | (EBIT / Operating revenue) * 100 | Amadeus |
| Cash flow / Operating revenue (%) | (Cash flow / Operating revenue) * 100 | Amadeus |

Tab. 42 Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 4. část

| Ukazatel | Výpočet | Zdroj |
|---|--|----------------|
| Net assets turnover (x) | Operating revenue / (Shareholders funds + Non current liabilities) | Amadeus |
| Interest cover (x) | Operating profit / Interest paid | Amadeus |
| Stock turnover (x) | Operating revenue / Stocks | Amadeus |
| Collection period (days) | (Debtors / Operating revenue) * 360 | Amadeus |
| Credit period (days) | (Creditors / Operating revenue) * 360 | Amadeus |
| Current ratio (x) | Current assets / Current liabilities | Amadeus |
| Liquidity ratio (x) | (Current assets - Stocks) / Current liabilities | Amadeus |
| Shareholders liquidity ratio (x) | Shareholders funds / Non current liabilities | Amadeus |
| Solvency ratio (Asset based) (%) | (Shareholders funds / Total assets) * 100 | Amadeus |
| Solvency ratio (Liability based) (%) | (Shareholders funds / (Non current liabilities + Current liabilities)) * 100 | Amadeus |
| Gearing (%) | ((Non current liabilities + Loans) / Shareholders funds) * 100 | Amadeus |
| Operating revenue per Employee (th) | Operating revenue / Employees | Amadeus |
| Costs of employees / Operating revenue (%) | (Cost of employees / Operating revenue) * 100 | Amadeus |
| Average cost of employee (th) | Cost of employees / Employees | Amadeus |

Tab. 43 Seznam všem poměrových ukazatelů, červené se objevily v konečném modelování 5. část

| Ukazatel | Výpočet | Zdroj |
|--------------------------------------|--------------------------------|--------------|
| Shareholders funds per employee (th) | Shareholders funds / Employees | Amadeus |
| Working capital per employee (th) | Working capital / Employees | Amadeus |
| Total assets per employee (th) | Total assets / Employees | Amadeus |

C Seznam všech makroekonomických ukazatelů

Tab. 44 Seznam makroekonomických proměnných, červené se objevily při konečném modelování

| Ukazatel | Jednotka |
|-----------------------------------|--------------------|
| HDP | %, r/r, reálně |
| Výdaje na konečnou spotřebu | %, r/r, reálně |
| z toho: spotřeba domácností | %, r/r, reálně |
| Výdaje na tvorbu hrubého kapitálu | %, r/r, reálně |
| z toho:fixního | %, r/r, reálně |
| Vývoz zboží a služeb | %, r/r, reálně |
| Dovoz zboží a služeb | %, r/r, reálně |
| Domácí realizovaná poptávka | %, r/r, reálně |
| Souhrnná produktivita práce | %, r/r |
| Jednotkové pracovní náklady | %, r/r |
| Průmysl - tržby | %, r/r, běžné ceny |
| Stavební produkce | %, r/r, reálně |
| Zemědělství- tržby | %, r/r, reálně |
| Obecná míra nezaměstnanosti | %, průměr |
| Průměrné reálné mzdy | %, r/r |
| Míra inflace | %, r/r, průměr |
| Ceny průmyslových výrobců | %, r/r, průměr |
| Ceny stavebních prací | %, r/r, průměr |
| Ceny tržních služeb | %, r/r, průměr |
| Ceny vývozu zboží | %, r/r, průměr |
| Ceny dovozu zboží | %, r/r, průměr |
| CZK/EUR | průměr |
| CZK/USD | průměr |
| Nominální efektivní kurz | % |
| Reálný efektivní kurz | % |

D Klasifikační funkce pro oborový model sekce A: Zemědělství, lesnictví a rybářství

Tab. 45 Klasifikační funkce grupovací pro obor Zemědělství, lesnictví a rybářství bez makroekonomických proměnných

| Proměnná | Přiřazení Záporná EVA | Přiřazení Kladná EVA |
|--|--------------------------|-------------------------|
| EVA 2005-2013 | -0,00019 | -0,00013 |
| Financial Leverage % Other Shareholders Funds/Total Assets | 6,98969 | 8,20661 |
| Debt Equity ratio % (Non-Current Liabilities+Current Liabilities)/Shareholders Funds | 1,23994 | 1,44727 |
| Rentabilita tržeb % (Operating P/L [=EBIT/Operating revenue (Turnover)]) | 15,25068 | 19,03200 |
| Doba obratu zásob Stocks/((Operating revenue (Turnover)/360) | 0,06308 | 0,05961 |
| Konstanta | -6,31336 | -6,70123 |