

Obsah

Rubrika *Stati*

<i>Lukáš Hruboš: Násobek EV / EBITDA: praktické poznámky k aplikaci</i>	3
<i>Martin Husák – Petr Marek: Odchyly ocenění při sestavení odvětvových multiplikátorů na amerických společnostech</i>	18
<i>David Chudomský – Radana Šmídová: Kvantifikace výnosnosti vlastního kapitálu Budějovického Budvaru při alternativní finanční struktuře – případová studie</i>	38
<i>Veronika Staňková: Může být strojové učení užitečné ve financích podniku a jeho ocenění? Přehled současného výzkumu</i>	53

Editorial

Vážení čtenáři,

předkládáme Vám čtvrté číslo čtrnáctého ročníku našeho časopisu Oceňování. V tomto čísle jsme pro Vás připravili čtyři hlavní příspěvky v rubrice Stati, zabývající se vybranými problémy souvisejícími s tématem oceňování majetku.

Lukáš Hruboš navazuje na své předchozí články zabývající se násobkem EV / EBITDA, které jsme v minulosti zveřejnili v časopise Oceňování. Tentokrát analyzuje vybrané faktory výše EBITDA marže s důrazem na vliv outsourcingu, využití nájmu a leasingů, specifické účetní politiky a transakcí se spřízněnými osobami. Na příkladu demonstruje, že i oborová „peers“ mohou mít nejen výrazně jinou EBITDA marži, ale v důsledku rozdílných rizikových, růstových a investičních profilů také odlišnou výši násobku EV / EBITDA.

Martin Husák a Petr Marek z katedry financí a oceňování podniku VŠE se ve svém příspěvku zaměřují na odchylky ocenění při sestavení odvětvových multiplikátorů. Cílem empirického výzkumu bylo stanovit na vzorku společností obchodovaných na americkém kapitálovém trhu vlastní hodnoty šesti nejčastěji používaných multiplikátorů pro americký trh, zvláště pro medián a zvláště pro aritmetický průměr, a následně pro účely vhodnosti případného použití zjistit odchylky u těchto hodnot z hlediska velikosti společnosti, odvětví, velikosti společnosti v odvětví, času a vůči hodnotám Damodaranových multiplikátorů.

Článek Davida Chudomského a Radany Šmídové z katedry financí a oceňování podniku VŠE se zabývá finanční strukturou podniku a jejím vlivem na výnosnost pro vlastníka. V rámci případové studie je analyzován významný český pivovar Budějovický Budvar s konzervativní finanční strukturou. Hlavním cílem je analýza výnosnosti vlastního kapitálu při alternativní finanční struktuře podniku při zohlednění vyššího finančního rizika, způsobeného zvýšenou finanční pákou.

Současným výzkumem v oblasti strojového učení se ve svém příspěvku zabývá Veronika Staňková z katedry financí a oceňování podniku VŠE. Kromě analýzy jednotlivých modelů strojového učení a zhodnocení jejich výhod a nevýhod se autorka zaměřila na otázku jejich využití v oblasti financí podniku a oceňování.

Prosíme vážené čtenáře, aby články považovali za názory autorů, které mohou být vhodným východiskem k diskusi.

Věříme, že pro Vás bude náplň časopisu přínosná a těšíme se na další příspěvky z praxe i akademické půdy.

Ing. Radana Šmídová, Ph.D.
šéfredaktorka časopisu Oceňování

Násobek EV / EBITDA: praktické poznámky k aplikaci

*Lukáš Hruboň**

Úvod

Na základě svých 15-letých praktických zkušeností s transakcemi typu nákup a prodej podniku si dovoluji konstatovat, že (i) veličina upravený zisk před úroky, daněmi a odpisy (EBITDA), respektive (ii) její dopad na ocenění podniku prostřednictvím násobku Enterprise Value / EBITDA (EV / EBITDA) je v českých realitách mimo sektor finančních institucí stále nejužívanějším konceptem při stanovení hodnoty a potažmo vyjednávání o akviziční ceně cílové společnosti.¹

Potenciální kupující často stanovuje cenu v první nezávazné nabídce pouze na základě dostupných účetních výkazů cílové společnosti, respektive svého interního či oborového násobku EV / EBITDA. V pokročilejších fázích transakce pak zájemce o akvizici sestaví detailnější oceňovací výnosový model, přičemž se diskuse mezi protistranami často opět vrací k hodnotě násobku. Ještě jednou si tak dovoluji porozumění celé problematice opětovně otevřít a upozornit na sporná místa aplikace metodiky.

V minulých příspěvcích² jsem se zabýval:

- teoretickou, empirickou a praktickou vhodností oceňovacího násobku EV / EBITDA;
- lineární regresí vlivu tzv. fundamentálních faktorů ovlivňujících výši násobku na datech z Varšavské akciové burzy;
- návrhem vhodného postupu pro kvantifikaci *upravené* EBITDA, respektive souměrných veličin *upraveného* Čistého pracovního kapitálu a Čistého dluhu.

Tímto pojednáním uzavřu celou „sérii“, přičemž se zaměřím na diskusi následujících bodů:

- Proč mohou mít dvě obdobně velké firmy, které poskytují zákazníkům na jednom území stejnou službu, výrazně jinou %-ní EBITDA marži (definovanou jako EBITDA / Tržby)?
- Proč se liší typické hodnoty násobku mezi jednotlivými obory, respektive u firem v oboru?
- EBITDA kterého roku je vhodná základna pro ocenění pomocí násobku?

* Ing. Lukáš Hruboň, Ph.D., ACCA, znalec ve specializaci Oceňování podniků.

¹ Odkaz na starší empirický výzkum je obsažen v Hruboň (2014b).

² detailní odkazy na literaturu - viz sekce Zdroje

EBITDA – zopakování základních pojmů

Koncept EBITDA

EBITDA je jedním z měřítek provozní ziskovosti firmy. Účetní výsledek hospodaření je upraven tak, aby neobsahoval vliv následujících komponent výkazů zisku a ztráty:

Úroky – nákladové úroky z titulu financování (bankovní úvěry, akcionářské půjčky apod.) a výnosové úroky plynoucí z peněžních prostředků nad rámec provozně nutného zůstatku jsou vyloučeny jako položka odrážející finanční strukturu společnosti;

Daně – splatná (a odložená) daň z příjmů právnických osob není zohledněna;

Odpisy – odpisy dlouhodobého hmotného a nehmotného majetku nepředstavující peněžní výdaj jsou přičteny zpět k hospodářskému výsledku.

S využitím veličiny EBITDA se pojí následující výhody a omezení:

(+)	možnost mezinárodního srovnání firem bez ohledu na daňovou pozici, způsob financování či účetní odpisové politiky
(+)	potenciálně menší volatilita oproti ukazatelům cash flow
(-)	rozdílné účetní politiky mohou deformovat výši ukazatele
(-)	EBITDA nezohledňuje investiční náročnost firmy

Koncept upravené EBITDA

Základní EBITDA, kterou je možno vypočíst pouze z účetních výkazů, je dále vhodné upravit o položky potenciálně zkreslující její vypovídající schopnost tak, že má veličina následující kvality:

Upravená EBITDA (v Kč)

1. je primárně ukazatelem na *akruální roční* bázi, tj. realizace peněžního toku v daném období není rozhodující;
2. vyjadřuje *aktuální* úroveň výkonnosti (očekávaný vývoj ziskovosti v delším časovém horizontu zachycuje výše násobku);
3. zohledňuje ziskovost na *dlouhodobě udržitelné* bázi (anglicky „recurring“);
4. vztahuje se k *provozní* aktivitě („operating“) na bázi *hlavní činnosti* podniku („core“);
5. relevantní náklady a výnosy bez známé přesné výše jsou kalkulovány na bázi nejlepšího expertního odhadu.

Analýza fundamentálních faktorů EV / EBITDA

V minulém příspěvku Hruboň (2014b) jsme odvolili následující základní vztah mezi násobkem EV / EBITDA a fundamentálními faktory jeho hodnoty následovně:

$$\frac{EV}{EBITDA} = \frac{(1 - t + \frac{t \times DA}{EBITDA} - \frac{I}{EBITDA})}{(WACC - g)}, \quad (1)$$

kde	EV	- Enterprise Value (Kč),
	EBITDA	- Earnings before Interest, Taxes, Depreciation and Amortization (Kč),
	t	- sazba splatné daně z příjmů (%),
	DA	- odpisy a amortizace dlouhodobého majetku (Kč),
	I	- investice do dlouhodobého majetku a čistého pracovního kapitálu (Kč),
	WACC	- průměrné vážené náklady investovaného kapitálu,
	g	- očekávaný růst.

Poznámka: Část vzorce $t - t \times DA / EBITDA$ reprezentuje míru zdanění EBITDA. Ohledně volby výše t přichází v úvahu dva následující postupy: 1) t odpovídá *nominální* daňové sazbě (tj. v současnosti 19 % v České republice). 2) Použijeme *efektivní* daňovou sazbu, která se může od nominální odlišovat v důsledku: a) dočasných odchylek splatné daně například v návaznosti na uplatnění daňových ztrát, odpočtu na výzkum a vývoj, respektive zrychlených daňových odpisů; b) stálých odchylek nejčastěji ve formě daňové neuplatnitelnosti určité části opakovaných nákladů. Výpočet dle vzorce (1) by ideálně měla ovlivnit efektivní daňová sazba po zohlednění pouze stálých odchylek od nominální daňové sazby.

Z dekompozice vyplývá, že násobek EV / EBITDA je *ceteris paribus* veličinou klesající v důsledku (i) vyšší míry zdanění t , (ii) vyšší investiční míry $I / EBITDA$, (iii) vyššího požadovaného výnosu z kapitálu WACC; respektive rostoucí s (iv) vyšším daňovým štítem z odpisů a (v) vyšší mírou očekávaného růstu g .

Rozdílná výše EBITDA marže u podobných firem v oboru

V této sekci se zaměříme na diskusi možných distorzí EBITDA marže v důsledku využití specifických provozních, finančních či účetních politik. Marži EBITDA v % definujeme jako $EBITDA / \text{tržby}$. Poznámka: V následujícím textu předpokládáme, že finanční analytik má přístup k interním informacím o nákladových strukturách oceňované firmy.

Vliv outsourcingu

Outsourcing může nabývat následujících základních podob:

a) poskytnutí komplexní služby na klíč dodavatelem:

a1 – u klíčových podnikových procesů (např. subdodávky stavebních prací stavební firmě či logistických služeb dopravci),

a2 – u obslužných podnikových procesů (např. právní a účetní servis);

b) poskytnutí výrobních faktorů:

b1 – poskytnutí dlouhodobého majetku: nájmy a leasing,

b2 – výkon typických zaměstnaneckých činností prostřednictvím pracovních agentur,

b3 – výkon typických zaměstnaneckých činností prostřednictvím spolupracujících OSVČ.

Ad a): Pokud se firma rozhodne komplexně svěřit část podnikových procesů externímu subjektu, tento bude zřejmě fakturovat své dodávky v ceně obsahující alokaci odpisů, finančních nákladů, daně z příjmů a své ziskové přírážky. *Ceteris paribus* tak outsourcing bude snižovat EBITDA marži. Na druhou stranu společnost může realizovat nižší provozní páku (podíl fixních nákladů) či dosáhnout lepší škálovatelnosti produkce. To může ovlivnit veličiny WACC, respektive g . Externalizace procesů tak mimo EBITDA marže může také ovlivnit výši oceňovacího násobku – viz *další subkapitola*.

Ad b): Problematice nájmu a leasingů se budeme věnovat v následující subkapitole. Při širokém využití pracovních agentur platí obdobné závěry jako v předchozím odstavci.

Při podnikové analýze je také nutno vzít v úvahu, zda není ve velkém objemu praktikován tzv. „švarcsystém“.³ Pokud tomu tak je, „chybí“ v nákladech oceňované firmy minimálně sociální a zdravotní pojištění zaměstnavatele (v současnosti 33.8 %). Za předpokladu, že by spolupracující lidská síla očekávala po převodu do zaměstnaneckého poměru stejný čistý příjem, je koeficient dodatečných nákladů až 70 % dosud fakturované ceny, a to především v závislosti na režimu výdajového paušálu uplatňovaného spolupracující OSVČ.

Leasingy a jejich vykazování: ČÚS vs. IFRS 16

Dle Českých účetních standardů jsou náklady leasingu rozeznávány akruálně v položce služby. V časovém rozlišení se objeví mimořádné platby (či jejich odklady), zatímco závazky jsou zachyceny jen ve výši posledního fakturačního období. Reportovaná EBITDA je tak nižší, zatímco není vykázán žádný závazek z titulu financování.

Dle IFRS je pro významné dlouhodobé operativní leasingy a finanční leasingy rozeznáno v aktivech právo k užívání aktiva, respektive quasi-úvěrový závazek. Výše závazku je spočtena jako současná hodnota zbývajících leasingových splátek / nájemného po dobu trvání smlouvy. Výsledovka je pak ovlivněna prostřednictvím odpisů práva k užívání, respektive implicitních finančních nákladů. Je tak zjevné, že poslední úprava IFRS 16 (Leasingy) oproti ČÚS zvyšuje hodnoty EBITDA. Standard IFRS 16 tak vlastně usiluje o zvýšení srovnatelnosti EBITDA marže firem, které mají odlišné provozní modely z hlediska vlastnictví vs. leasingů / nájmu dlouhodobého majetku.

Této často nemalé distorze si musí být oceňovatel vědom a nepracovat tak s poskytnutými finančními výkazy pouze mechanicky. EBITDA zjevně není dle rozdílných účetních standardů vždy totéž. Klíčovým faktorem aplikace tržní metody je zajištění konzistence pojetí EBITDA oceňované firmy a této ziskovosti ve vzorku srovnávaných firem. Pokud budeme používat pro rámcový benchmark násobky ze zemí, kde je aplikováno IFRS či obdobný přístup, budou příslušné násobky *ceteris paribus* nižší, než při jejich výpočtu na základě českých účetních předpisů.

³ Švarcsystém znamená v kostce nákup služeb lidské síly, které naplňují charakteristiky pracovněprávního poměru, ale jsou realizovány spolupracujícími OSVČ. Tím dochází ke značné daňové úspoře zejména na odvodech sociálního a zdravotního pojištění. Další úspora je realizována na úrovni daně z příjmu fyzických osob zaměstnance vs. OSVČ.

Poznámka: Z hlediska veličiny *upravená* EBITDA se autorovi zdá vhodnější u často se pravidelně opakujících typu nájem nemovitostí jejich pojetí dle ČÚS.

U opakovaných leasingů nejčastěji vozů je v praxi možno jít oběma cestami: (i) leasing je ponechán v provozních nákladech – ČÚS přístup vs. (ii) je fakticky zaúčtován jako spotřebitelský úvěr na auto – IFRS pohled. Při aplikaci druhé metody je však nutno mít na paměti, že vyčíslení závazku musí respektovat *průměrnou* hodnotu typického cyklu pořízení aktiv (splacení implicitního dluhu).

Pokud je na leasing pořízen „mimořádně“ významný dlouhodobý majetek s dlouhodobou životností, jeví se jako vhodnější respektovat přístup dle IFRS.

Zásoby vs. dlouhodobý majetek

S určitou benevolencí klasifikace aktiv jako zásoby vs. dlouhodobý majetek se setkáváme například u autosalónů. Část vozů, které management *de facto* zamýšlí k prodeji koncovému zákazníkovi, je po dobu až jednoho roku evidována jako odepisovaný dlouhodobý majetek (předváděcí a záložní vozidla). Tím se efektivně snižuje ve výsledovce položka náklady prodaného zboží, jelikož pořizovací cena vozů je před jejich prodejem zákazníkovi snižována prostřednictvím odpisů. Záleží samozřejmě na poměru takto prodáváných vozů, délce jejich držení v rámci dlouhodobého majetku a faktu, zda nebyly po dobu do prodeje skutečně významněji opotřebeny, což je spojeno s významnější redukcí prodejní ceny. Finanční analytik by si však měl uvědomit, že v případě nadužívání takového režimu je EBITDA i její marže „uměle“ zvyšována.

Vnitroskupinové obchodování / transakce se spřízněnými osobami

Častou výzvou srovnávacích analýz v oboru je omezená možnost odstínit vliv transakcí se spřízněnými osobami. V případě, že má analytik přístup k příslušným datům, je vhodné úroveň *upravené* EBITDA korigovat zejména o transakce bez tržní podstaty nebo oceněné na mimotržní úrovni. Přes značný důraz na vymáhání pravidel „transfer pricing“ v nedávných letech, existuje vždy určitá míra „benevolence“ pro určení ceny obvyklé v takových transakcích. Navíc se nezdá, že dokumentace převodních cen předkládaná finanční správě opírá o tržní srovnání ziskových marží u společností v oboru. Vzniká tak vlastně do určité míry začarovaný kruh. Transakce, které často ovlivňují EBITDA marži při oborovém srovnání, jsou například tzv. „management fees“, osobní spotřeba majitele či netržní předávací cena.

Příklad I. a) Srovnání logistických firem

Některé z výše uvedených bodů si demonstrujeme na hypotetickém příkladu z oboru logistika. Budeme porovnávat dvě firmy poskytující služby dodávek poslední míle se stejnou velikostí tržeb. Jedna z nich se však rozhodla jít cestou téměř komplexního outsourcingu logistiky, přičemž druhá disponuje vlastním vozovým parkem a týmem řidičů. Základní charakteristiky obou společností jsou uvedeny níže:

	Logistik A	Logistik B
Popis firmy		
Role vlastníka / managementu	Závislost na vlastníkově f.o.	Závislost na vlastníkově f.o.
Zaměření	Doručení zásilek koncovému uživateli	Doručení zásilek koncovému uživateli
Lokalita	Praha a okolí	Praha a okolí
Skladovací prostory	V pronájmu	V pronájmu
Flotila	Outsourcing logistiky na klíč subdodavateli (+) 5 vozů na operativní leasing	Vlastní flotila - 55 vozů v dlouhodobém majetku - pořízená ze zisků minulých let
Základní provozní charakteristiky		
Počet řidičů	3	55
Průměrná superhubá mzda řidiče p.m. (kCZK)	60	60
Marže po subdávce logistických služeb	32%	n.a.
Operativní leasing p.m. (kCZK)	100	n.a.
Spotřeba paliva na 1 vůz p.a. (CZK)	1,313	1,313
Průměrná cena vozu	n.r.	900
Doba / obnovy odepisování vozů v letech	3	3

Položky lišící se u Logistik A vs. B

Rozdílné obchodní modely pak mají následující dopady ve výsledovce, respektive cash flow (vše v kCZK – tis. Kč):

	Logistik A	Logistik B
Základní finanční charakteristiky		
Tržby	200,000	200,000
Subdávka logistických služeb na klíč	(136,000)	-
Palivo	(6,563)	(72,188)
Mzdové náklady řidičů	(2,160)	(39,600)
Operativní leasing	(6,000)	-
Logistická EBITDA	49,278	88,213
% marže	24.6%	44.1%
Ostatní provozní výnosy a náklady (mimo odpisy)	(35,000)	(40,000)
EBITDA	14,278	48,213
% marže	7.1%	24.1%
Odpisy flotily	-	(16,500)
EBIT	14,278	31,713
% marže	7.1%	15.9%
Daně z EBIT (@ 19%)	(2,713)	(6,025)
CAPEX	-	(16,500)
Investice do ČPK	-	-
FCFF	11,565	25,687
% marže	5.8%	12.8%

Zdroj: Vlastní zadání a výpočty

Z rozboru finančních výkazů vyplývá, že i když jsou tržby (potažmo typ koncového zákazníka) u obou firem stejné:

- Logistická marže EBITDA Logistika B je o 19.5 p.b. vyšší.
- Tento fakt je v rámci FCFF marže korigován vyšší provozní režii (údržba plus personální obsluha vozového parku, respektive HR agendy řidičů) a investicemi do dlouhodobého majetku. FCFF marže Logistika B je lepší pouze o 7 p.b.

Otázkou je, **zda na obě reportované EBITDA aplikovat stejný násobek**, se budeme zabývat v následující kapitole.

Fundamentální výpočtový přístup k násobku EV / EBITDA

Jak naznačují data z databáze Mergermarket, celkový násobek odvozený z trhu fúzí a akvizic ve střední a východní Evropě vykazuje stacionární povahu. Dočasné výkyvy směrem nahoru i dolů mohou být dány jak vývojem rizikového apetitu či přístupu k volnému kapitálu v čase, tak nízkým počtem pozorování v jednotlivých letech.

Tab. 1: Mediánový násobek EV / EBITDA v regionu CEE

Rok	Počet pozorování	Medián EV / EBITDA
2021	9	10.4
2020	20	7.8
2019	33	8.2
2018	16	9.5
2017	6	5.9
2016	27	7.4
2015	46	8.7
Celkem	157	8.4

Zdroj: Mergermarket

Poznámka: zahrnuje státy visegrádské čtyřky, bývalé Jugoslávie a Bulharsko; transakce se zveřejněnou cenou a EBITDA; hodnota transakce > USD 5 mil. (omezení poskytovatele databáze); vyloučení násobků s hodnotou > 50 (úprava provedená autorem).

V letech, kde bylo k dispozici alespoň 20 pozorování, se násobek pohyboval v intervalu: 7,4 – 8,7. Jako východisko výpočtové analýzy fundamentálních faktorů nám pak poslouží porovnání typických násobků EV / EBITDA mezi jednotlivými obory.

Tab. 2: Mediánový násobek EV / EBITDA dle oborů

Země CEE, roky 2015-2021	
Mining	3.7
Energy	5.1
Computer services	5.4
Chemicals and materials	6.0
Telecommunications: Carriers	6.2
Industrial products and services	6.4
Consumer: Foods	6.5
Construction	6.7
Medical	7.1
Automotive	7.8
Transportation	7.9
Manufacturing (other)	8.2
Consumer: Retail	9.0
Financial Services	9.1
Services (other)	9.9
Industrial automation	10.0
Real Estate	10.4
Utilities (other)	11.3
Medical: Pharmaceuticals	11.6
Leisure	11.9
Agriculture	13.0
Computer software	13.4
Consumer: Other	13.8
Internet / ecommerce	14.0
Media	15.2
Biotechnology	28.6

Zdroj: Mergermarket

Ve výše uvedeném přehledu si můžeme mimo jiné povšimnout, že:

- Nízko jsou ohodnoceny firmy v oborech vystavených volatilním komoditním cenám, respektive obecně s vysokým podílem fixních aktiv (těžba surovin a energetika). U těžby surovin navíc nelze předpokládat výrazné rozšiřování aktivit do budoucna.
- Uprostřed spektra se nachází většina tradičních výrob a služeb.
- Násobky nemovitostních firem jsou i přes nutné investice a omezený růstový potenciál nadprůměrné, a to v důsledku dobrého rizikového profilu. Totéž platí pro síťová odvětví.
- Vysokým násobkům se těší obory se značným očekávaným růstem (e-commerce a biotechnologie).

V kostce se tak opět vracíme k rovnici (1), která popisuje fundamentální faktory násobku EV / EBITDA. Vyšší násobky budou dosahovat obory / firmy s:

- vyšším očekávaným růstem (vyšší g),
- lepším rizikovým profilem (nižší WACC),
- nižší investiční náročností (nižší $I / EBITDA$),
- nižší mírou zdanění EBITDA (nižší $t - t \times DA / EBITDA$).

Autor tak navrhuje, že relativně přístupným analytickým řešením je výpočet násobku EV / EBITDA přímo dle vzorce (1). Tento výpočet může být následně porovnán s násobky dosahovanými na trhu. K výpočtu jednotlivých komponent lze přistoupit následovně:

Rizikový profil firmy „WACC“

Stanovíme standardními přístupy popsány v odborné literatuře – základně Mařík (2007). Poznámka: Autor nepovažuje základní analýzu WACC jako úkon s vysokou časovou náročností.

Investiční náročnost „I / EBITDA“

Investice do dlouhodobého majetku a čistého pracovního kapitálu stejně tak jako EBITDA vyčíslíme na základě přiměřené dlouhé historické řady účetních výkazů. Dále vypočteme historickou investiční náročnost a aplikujeme reprezentativní poměr, případně upravený na základě konzultace s management oceňované společnosti.

Sazba daně z příjmu právnických osob na úrovni EBITDA „ $t - t \times DA / EBITDA$ “

Postupujeme obdobně jako v předchozím odstavci. Firmy s vyšší investiční náročností na dlouhodobý majetek budou částečně vyvažovat tuto „nevýhodu“ prostřednictvím dodatečných daňových štítů z odpisů.

Očekávaný růst „g“

Vzhledem k různým růstovým potenciálům konkrétní firmy i oborů se autor tohoto pojednání domnívá, že je vhodné zjednodušeně modelovat očekávaný růst EBITDA v duchu třífázového výnosového oceňovacího modelu. Míra růstu g , kterou použijeme pro výpočtový tvar násobku, odhadneme jako vážený průměr plánovaného růstu: (i) detailně v letech plánovacího horizontu, (ii) na „konvergenční“ úrovni v druhé fázi, respektive (iii) na typické úrovni g používané při modelování terminální fáze (často 1 – 3 % uvažovaného reálného růstu oboru / ekonomiky jako celku). Průměrná míra růstu je tak dána ročními mírami růstu, které by byly použity při konstrukci plného výnosového modelu. Demonstraci výpočetního postupu zachycuje Obrázek 1 níže.

Poznámka: Hodnoty růstu v 1. a 2. fázi lze určit zejména na základě konzultace s management oceňované společnosti a dostupných oborových studií.

Obr. 1: Výpočet vážené míry růstu do nekonečna – příklad („Logistik A“)

Plánovací horizont >>>	1. fáze					2. fáze					Terminální hodnota
Rok plánu >>>	1	2	3	4	5	6	7	8	9	10	11
g [1]	15.0%	10.0%	7.0%	5.0%	3.0%	2.0%	2.0%	2.0%	2.0%	2.0%	1.5%
WACC	11.0%										
Diskontní faktor [2]	0.90	0.81	0.73	0.66	0.59	0.54	0.48	0.43	0.39	0.35	3.22
Vážené g	4.5%					Vážený průměr vypočtený z [1] a [2]					
Podíl na hodnotě	1. fáze					2. fáze					Terminální hodnota
	40.6%					24.1%					35.3%
Vstupy výpočtu											

Zdroj: Vlastní výpočty

Příklad I b) Srovnání logistických firem - pokračování

Navržený postup kvantifikace násobku na základě fundamentálních faktorů dále demonstrujeme prostřednictvím případové studie poskytovatelů logistických služeb popsanych v Příkladu I. a. Jedná se o investorské (subjektivní) ocenění obou firem.

	Logistik A	Logistik B
Fundamentální faktory násobku EV / EBITDA		
Investiční náročnost EBITDA	-	0.342
Efektivní daňová sazba z EBITDA	0.190	0.125
Podíl fixních nákladů na tržbách	0.216	0.481
WACC		
Bezriziková úroková míra (R_f)	4.0%	4.0%
Riziková přírážka trhu (MRP)	5.5%	5.5%
Podíl dluhu na Enterprise Value	10%	10%
Beta nezadlužená - obor (<i>Beta unlevered</i>)	0.8	0.8
Mediánový podíl fixních nákladů v oboru	0.21	0.21
Beta nezadlužená zohledňující výši fixních nákladů	0.8	1.8
Beta zadlužená	0.9	0.9
Celková přírážka / (srážka) k Beta nezadlužené	0.1	1.1
Celková Beta	0.9	1.9
Specifická přírážka k nákladům vlastního kapitálu za neobchodovanost a rizika malé firmy	3.0%	3.0%
Sazba dluhu po dani	2.4%	2.4%
WACC	11.0%	16.0%
Průměrný vážený růst (do nekonečna)	4.5%	3.0%
Ocenění firmy Enterprise value (kCZK)		
Násobek EV / EBITDA k aplikaci na EBITDA ($t+1$)	12.5	4.1
EV	186,824	204,145

Zdroj: Vlastní výpočty

Poznámka: Fixní náklady = mzdové náklady (+) ostatní provozní výnosy a náklady (+) leasing (+) odpisy


Poznámka: ilustrativní hodnoty a mechanika výpočtu WACC nejsou předmětem diskuse tohoto článku

Povšimněme si zejména následujícího:

- Logistik B má významně vyšší investiční náročnost;
- Logistik B vykazuje nižší míru zdanění EBITDA v důsledku existence odpisů;
- Vyšší úroveň fixních nákladů firmy Logistik B s vlastními řidiči a flotilou v našem výpočtu ovlivňuje hodnotu upravené *Beta* směrem nahoru;
- Předpokládáme, že budování interních logistických kapacit bude v 1. fázi plánu omezovat růstový potenciál Logistik B oproti konkurentovi, který má k dispozici desítky volných subdodavatelů na trhu;
- Násobek podniku Logistik A je výrazně atraktivnější, než násobek konkurenta. **Rozdílná výše násobku částečně koriguje významnou odchylku na úrovni podkladové EBITDA;**
- Přesto na základě provedené analýzy Logistik B při stejné výši tržeb a stejné nabízené službě dosahuje vyšší Enterprise Value. To může být zejména spojené s a) atraktivnějším portfoliem zákaznických smluv, b) celkovou větší ekonomickou vhodností zvoleného obchodního modelu internalizace dopravní flotily;
- Poznámka: Ocenění výpočtovým tvarem násobku EV / EBITDA odpovídá ocenění dle „tradičního“ vzorce $FCFF / (WACC - g)$.

Analýza citlivosti násobku EV / EBITDA na hlavní vstupy výpočtu dle vzorce (1)

Pro lepší pochopení míry vlivu vybraných hodnototvorných vstupů, provedeme grafickou analýzu citlivosti výše násobku na jejich teoreticky přípustné (zhruba obvyklé) hodnoty.

Obr. 2: Citlivost EV / EBITDA na vybrané vstupy (data „Logistik A“)

Zdroj: Vlastní výpočty

Ze základní grafické analýzy citlivosti ocenění Logistik A vyplývá následující:

- Veličiny ovlivňující jmenovatel zlomku (1) mají nelineární průběh.
- Na zvolené škále přípustných hodnot (osa x v každém z grafů) vykazuje největší dopad volba parametrů *Beta* a zadlužení firmy. Vysoká investiční náročnost má potenciál nulovat hodnotu firmy.

- Změna *Beta* o 0,25: v okolí středu škály (zde = 1,0) vyvolá změnu v násobku o ca. 2,1.
- Změna *specifické přírážky* o 2 p.b.: v okolí středu škály (zde = 4,5 %) vyvolá změnu v násobku o ca. 1,5.
- Změna růst *g* o 1 p.b.: v okolí středu škály (zde = 4 %) vyvolá změnu v násobku o ca. 1,7.

Problém volby reprezentativního období EBITDA

Protistrany při vyjednávání detailně diskutují výši *upravené* EBITDA včetně její správné báze z hlediska času. Vzhledem k běžné délce akvizičního procesu přesahující jeden rok se nesoulad v náhledu na ocenění může prohloubit v případě, kdy EBITDA cílové společnosti meziročně výrazně vzroste či naopak dramaticky poklesne. Další výzvou jsou ocenění společností typu start-up dosahující v počátku své činnosti dvouciferných meziročních temp růstu. K dispozici se nabízí následující časové báze EBITDA:

1. poslední uzavřený fiskální rok

(+)	z hlediska kvality účetnictví: často se jedná o výsledky ověřené statutárním auditorem
(+)	z hlediska rizika: „potvrzená“ výkonnost
(-)	není vypovídající pro společnosti ve fázi rychlého růstu či náhlých obchodních problémů

2. očekávaný výsledek následujícího fiskálního roku

(+)	aktuální pohled na firmu ve fázi expanze či finančních obtíží
(-)	odhad EBITDA je spojen s rizikem
	Pozn.: odhad výsledku je v mnohých oborech na základě uzavřených smluv, regulace či tržních analýz relativně spolehlivý (pomineme-li externí šoky)

3. očekávaný výsledek posledního roku finančního plánu

(+)	pohled na start-up ve „stabilizovaném období“
(-)	odhad EBITDA je spojen s vysokým rizikem

4. výsledek posledních uzavřených 12 měsíců (Last twelve months – LTM)

(+)	empirická výkonnost – viz Klement, J. [5]
(+)	„myšlenkový“ kompromis mezi přístupy 1 a 2
(-)	dodatečné náklady měsíční analýzy, respektive auditu mimo tradiční curriculum (dle relevance)

Volba vhodného přístupu zůstává v kompetenci oceňovatele, respektive jeho uplatnění závisí na argumentačních schopnostech protistran při vyjednávání. Jak je nastíněno výše, každý postup může mít dle profilu oceňované firmy své teoretické opodstatnění. Klíčové však je, aby **posuzovaná EBITDA byla z časového hlediska konzistentní s použitým poměrem EV / EBITDA**. Dle autora z hlediska teoretické analýzy v čase T totiž nedává smysl, aby použitý násobek byl stejný při aplikaci na účetní období (T–1), fiskální rok LTM(T), nebo (T+1).

Vezměme například v úvahu firmu, která právě nastoupila fázi komercializace svého produktu a v prvních třech letech tak poroste meziročně o 50 %, dále se tempa růstu sníží k 10 %. Je zřejmé, že násobek aplikovaný na EBITDA(rok 1) bude z hlediska analýzy v čase T jiný, než násobek aplikovaný na EBITDA(rok 4). Vracíme se tak k výše uvedenému výpočtovému fundamentálnímu přístupu k násobku. Veličina, kterou je ve vzorci (1) vhodné přizpůsobit je parametr g vypočítaný jako vážený průměr.

Obdobně. Předpokládejme, že databáze srovnatelných obchodovaných firem či historických akvizičních transakcí poskytuje mediánový násobek oboru technicky vypočítaný poskytovatelem databáze jako $EV / EBITDA$ posledního účetně uzavřeného fiskálního roku k datu odečtení EV . Potom je takový násobek technicky správné aplikovat na hospodářské výsledky historického uzavřeného období oceňované firmy (tj. ne na očekávanou EBITDA probíhajícího či následujícího fiskálního roku).

Na tomto místě si dovoluji ještě jednou zdůraznit, že při využití násobků odvozených od firem v oboru je zapotřebí zajistit konzistenci oceňované firmy a srovnávacího vzorku zejména v: (i) růstovém potenciálu, (ii) rizikovém, respektive investičním profilu - obchodním modelu, (iii) účetním pojetí EBITDA a (iv) časové bázi EBITDA. V ideálním případě by finanční analytik měl vyhledat manuály poskytovatele dat, respektive výroční zprávy oborových firem a plně pochopit / ověřit, jak burzovní datové platformy či databáze historických akvizic EBITDA kalkulují, respektive jaké účetní politiky oborové firmy používají. Omezením tohoto detailního přístupu je komplexita spojená s vícenáklady analýzy

Závěr

V posledním článku zaměřeném na v akviziční praxi převážně používaný násobek $EV / EBITDA$ nejprve diskutuji vliv využití outsourcingu, leasingu, transakcí se spřízněnými osobami a specifických účetních politik na dosahovanou EBITDA marži. Na příkladu dvou modelových konkurentů v sektoru logistiky demonstruji, že i oborová „peers“ mohou mít nejen výrazně jinou EBITDA marži, ale v důsledku rozdílných rizikových, růstových a investičních profilů také odlišnou výši násobku $EV / EBITDA$. Jiný způsob realizace investic do dlouhodobého majetku nutně ovlivní nejen výši EBITDA, ale také výši násobku. V závěrečné části upozorňuji na teoretické limity aplikace stejné výše násobku na historickou i očekávanou EBITDA firmy. Oceňovatel by měl při aplikaci násobku $EV / EBITDA$ jednat obezřetně a v maximální možné míře se ujistit při srovnávání firem ze stejného oboru o následujícím:

- EBITDA marže není deformována cenami mimo trh – např. transakcemi bez ekonomické podstaty se spřízněnými osobami či rozsáhlým užitím „švarcystému“ u jedné z firem,
- EBITDA marže není nežádoucím způsobem ovlivněna specifickými účetními politikami – např. faktické zásoby účtované jako dlouhodobý majetek či různé pojetí leasingů v ČÚS vs. IFRS,
- násobek $EV / EBITDA$ korektně zohledňuje různé růstové, rizikové a investiční profily každé z firem.

Literatura:

- [1] Hruboň, L. (2014b): Násobek EV / EBITDA: význam, analýza fundamentálních faktorů, Oceňování, číslo 3/2014, ISSN 1803-0785.
- [2] Hruboň, L. (2016): Násobek EV/EBITDA: Regresní analýza fundamentálních faktorů - data z WSE v letech 2012 - 2014, Oceňování, číslo 6/2016, ISSN 1803-0785.
- [3] Hruboň, L. (2017): Násobek EV / EBITDA: kvantifikace veličiny EBITDA, Oceňování, číslo 3/2017, ISSN 1803-0785.
- [4] Hruboň, L. (2018): Násobek EV / EBITDA: upravená EBITDA – symetrický obraz v rozvaze, Oceňování, číslo 1/2018, ISSN 1803-0785.
- [5] Klement, J. (2016): Dumb Alpha: Trailing or Forward Earnings? [ON-LINE], <https://blogs.cfainstitute.org/investor/2016/07/12/dumb-alpha-trailing-or-forward-earnings/>
- [6] Mařík, M. aj. (2007): Metody oceňování podniku: Proces ocenění, základní metody a postupy. 2. vydání. Praha, Ekopress, 2007. ISBN 978-80-86929-32-3.

Násobek EV / EBITDA: praktické poznámky k aplikaci

Lukáš Hruboň

ABSTRAKT

Tento příspěvek analyzuje vybrané faktory výše EBITDA marže s důrazem na vliv: (i) outsourcingu, (ii) využití nájmu a leasingů, (iii) specifické účetní politiky, (iv) transakcí se spřízněnými osobami. Autor dále upozorňuje na rizika „slepé“ aplikace uniformního oborového násobku EV / EBITDA na každou firmu splňující kritérium stejné poskytované služby / zákazníka. Oceňovatel by se měl při aplikaci metody tržního srovnání vždy v maximální možné míře ujistit, že je zajištěna konzistence mezi předmětem ocenění a oborovými „peers“ v a) účetních politikách ovlivňujících výsledovku a stejném postupu pro výpočet EBITDA; b) užití stejné báze fiskálního roku vstupujícího do výpočtu násobku; c) růstovém potenciálu, rizikovém profilu a investiční náročnosti jednotlivých uvažovaných firem.

Klíčová slova: Tržně srovnávací metoda; násobek EV / EBITDA; marže EBITDA, IFRS 16.

EV / EBITDA Multiple: EBITDA Quantification

ABSTRACT

This article analyses selected factors affecting EBITDA margins with focus on effects of: (i) outsourcing, (ii) rentals and leases utilization, (iii) specific accounting policies, (iv) transactions with related parties. Further, the author warns against “blind” application of the uniform sectorial EV / EBITDA multiple on each company fulfilling the same service provided / customer base criteria. A valuation expert attempting the market approach shall maximally double-check consistency between the valued company and its sectorial “peers” in: a) accounting policies affecting P&L and EBITDA calculation formula, b) application of the same fiscal year basis in the multiple’s computation, c) growth potential, risk profile and investment requirements of each of the companies in question.

Key words: Market based valuation; EV / EBITDA multiple; EBITDA margin; IFRS16.

JEL classification: G30

Odchyly ocenění při sestavení odvětvových multiplikátorů na amerických společnostech[#]

Martin Husák^{} – Petr Marek^{**}*

Úvod

Vedle běžně používaných metod ocenění společnosti, mezi které patří především metody výnosové, z nichž nejznámější je metoda diskontovaných peněžních toků, se stávají čím dál více atraktivní metody založené na analýze kapitálového trhu, též známé jako tržní metody (např. Demirakos – Strong – Walker, 2010). Tržní metody se liší podle toho, zda je společnost obchodována na kapitálovém trhu, poté jej nazýváme jako přímé ocenění z dat kapitálového trhu, nebo nikoli, pak se společnost oceňuje metodou tržního porovnání neboli na základě srovnatelných společností či srovnatelných transakcí.

Přímé ocenění z dat kapitálového trhu lze přirovnat k tržní kapitalizaci společnosti, která odpovídá tržní hodnotě vlastního kapitálu v určitý okamžik, ta se odvíjí od očekávané výnosnosti investorů na finančních trzích. Takové ocenění se ale v čase neustále mění v důsledku kontinuálního obchodování s akciemi společnosti. Další vliv na hodnotu ocenění mohou mít diskonty a prémie (např. Goedhart – Koller – Wessels, 2005), při nákupu minoritního či majoritního balíku akcií. Tato metoda není vhodná pro podniky, jejichž akcie nejsou aktivně obchodovány nebo jsou obchodovány pouze v omezeném objemu transakcí, zde můžeme hovořit například o českých společnostech obchodovaných na pražské burze.

Metody tržního porovnání vychází z principu analogie, při kterém hledáme podle různých faktorů (výnosnost, riziko, odvětví, aj.) podobné společnosti k námi oceňované společnosti. Existují dva přístupy, a tedy metoda srovnatelných společností, které jsou obchodované na kapitálových trzích, a metoda srovnatelných transakcí, tj. fúzí či akvizic obdobných společností. Obě metody fungují na stejné bázi navazující na postup komplexní finanční a strategické analýzy společnosti a srovnatelných společností završený volbou vhodných tržních násobků neboli multiplikátorů pro konkrétní případ a odvození konečné hodnoty akcie.

Problematika tohoto článku je věnována tržním odvětvovým multiplikátorům, které se od předchozí metody liší určením srovnatelných společností, které stojí na základě sledovaného odvětví. Metoda je v praxi využívána čím dál častěji a řada subjektů působících v oblasti oceňování a kapitálových trhů k ní přistupuje daleko pozitivněji, i přestože je dosud stále používána spíše jako podpůrná či doplňková k metodám výnosovým a majtkovým. Metoda je použitelná pouze v zemích s dostatečně rozvinutými kapitálovými trhy, proto se článek zaměřuje a zkoumá společnosti obchodované na americkém kapitálovém trhu.

[#] Článek je zpracován jako jeden z výstupů výzkumného projektu Fakulty financí a účetnictví na VŠE v Praze „Nové výzvy Corporate Finance v České republice 2.0“ registrovaného u Interní grantové agentury VŠE v Praze pod registračním číslem F1/58/2021 a jako jeden z výstupů výzkumného projektu Fakulty financí a účetnictví VŠE, který je realizován v rámci institucionální podpory VŠE IP100040. Podkladem k článku je diplomová práce Ing. Martina Husáka, vedená prof. Ing. Petrem Markem, CSc., obhájená na Katedře financí a oceňování podniku VŠE Praha v červnu 2021.

^{*} Ing. Martin Husák, doktorand, Katedra financí a oceňování podniku VŠE Praha.

^{**} Prof. Ing. Petr Marek, CSc., Katedra financí a oceňování podniku VŠE Praha.

Damodaran (2018) uvádí řadu důvodů pro použití metody tržních multiplikátorů. Tyto metody

- kladou nižší nároky na dostupnost dat, nákladovost a časovou náročnost procesu ocenění,
- nejsou náročné na pochopení, jednodušeji je lze prezentovat,
- jsou transparentní, jejich zpětná dopočitatelnost zamezuje subjektivním odhadům,
- odrážejí současnou situaci na kapitálových trzích i na odvětvové úrovni.

Cílem článku je stanovit vlastní hodnoty šesti nejčastěji používaných multiplikátorů pro americký trh, zvláště pro medián a zvláště pro aritmetický průměr, a následně pro účely vhodnosti případného použití zjistit odchyšky u těchto hodnot z hlediska velikosti společnosti, odvětví, velikosti společnosti v odvětví, času a vůči hodnotám Damodaranových multiplikátorů.

2. Odvětvové multiplikátory

2.1 Konstrukce multiplikátorů

Multiplikátory jsou ve své podstatě relativní ukazatele obvykle určené dvěma hlavními komponenty. Čitatel reprezentující cenu v určité měně vycházející z tržní hodnoty a jmenovatel, jenž představuje vybranou finanční proměnnou společnosti v téže měně, která odkazuje na výkonnost společnosti. Mezi čitatelem i jmenovatelem je důležitá určitá konzistence, např. pokud do čitatele dosazujeme tržní cenu akcie (P), pak do jmenovatele vkládáme čistý zisk na akcii (EPS). Pro získání výsledné hodnoty ocenění společnosti vynásobíme vztahovou veličinu dané společnosti se zvoleným multiplikátorem.

2.2 Dělení multiplikátorů

Multiplikátory dělíme do několika skupin z různých úhlů pohledu. V první řadě rozlišujeme entity a equity multiplikátory. Entity, někdy také nazývané jako enterprise value (EV), zastupuje hodnotu celé kapitálové struktury, a tedy pouze v případě, je-li společnost v nějaké míře zadlužena. Do jmenovatele multiplikátoru dosazujeme nejčastěji výsledek hospodaření před zdaněním a úroky (EBIT), EBIT před odpisy (EBITDA), EBITDA před náklady z nájemného (EBITDAR) či EBITDA před náklady na vědu a výzkum (EBITDAR&D) nebo také tržby (S). Equity vychází z tržní hodnoty vlastního kapitálu vztažené pouze k vlastníků společnosti. Zde se nejvíce používají P/EPS anebo namísto EPS do jmenovatele dosazená účetní hodnota vlastního kapitálu (BV), dividenda na akcii (DPS) či opět S. Equity multiplikátory vykazují přesnější výsledky ocenění společností (Schreiner – Spremann, 2007 a Nel – Bruwer – Roux, 2013). Mimo entity a equity se hojně užívají také tzv. Sector-specific multiplikátory, které vychází z nefinančních dat přímo vztažených pro daný sektor, např. počet megawattů u energetické společnosti nebo počet prodaných výtisků novin.

Jiné členění multiplikátorů, které souvisí s předchozím členěním, závisí na druhu vztahové veličiny. Může se jednat o ziskové multiplikátory sledující přidanou hodnotu ve

formě zisku, multiplikátory založené na účetní hodnotě (nejčastěji účetní hodnota vlastního kapitálu) nebo výnosové multiplikátory, přičemž dosazujeme do jmenovatele tržby (S).

2.3 Volba proměnných a způsob výpočtu multiplikátorů

Stěžejním úkonem při výpočtu multiplikátorů je volba vhodných proměnných. Vedle konzistence mezi čitatelem a jmenovatelem ve vztahu entity a equity je třeba sledovat proměnné také v čase (např. Alford, 1992, Budský – Dvořák, 2017). Podle Schreiner (2007) do čitatele hledáme poslední zveřejněnou hodnotu, má-li se odrážet od situace na trhu. Pokud tak učiníme, je třeba brát v úvahu, že v sobě nezahrnuje paralelní výsledek hospodaření. Výsledek hospodaření se běžně u větších společností zveřejňuje na čtvrtletní bázi s určitým zpožděním, a tedy je třeba uvažovat cenu, která v sobě již výsledek hospodaření zahrnuje.

Přejdeme-li ke jmenovateli, i zde je řada přístupů ke stanovení jeho hodnoty. Nejčastějšími způsoby jsou metoda současného zisku tzv. *current*, uvažující poslední zveřejněný výsledek hospodaření, metoda historického zisku tzv. *trailing*, zda se pracuje s průměrem za posledních 12 měsíců, a metoda očekávaného zisku tzv. *forward*, která bere v úvahu očekávané výsledky hospodaření po dobu následujících 12 měsíců. Poslední metoda je pro stanovení hodnoty multiplikátoru nejvhodnější (např. Lie – Lie, 2002, Schreiner – Spremann, 2007 a Liu – Nissim – Thomas, 2002), jelikož pracuje s očekávaným vývojem společnosti, avšak dostupnost těchto dat je v praxi velmi omezená.

Damodaran (2018) určuje odvětvové multiplikátory na bázi agregace položek všech společností v odvětví. Takový přístup lze v zásadě přirovnat k sestavení multiplikátorů za všechny společnosti v odvětví samostatně při použití stejné metriky a jejich následného zprůměrování. Metoda průměru je čím dál častěji kritizována z důvodu zkreslení v případě extrémních hodnot, což u multiplikátorů nastává téměř při každém výpočtu. Spíše, než aritmetický průměr se používá harmonický průměr (Baker – Ruback, 1999). Avšak i tak se praktici obecně přiklání k použití mediánu.

2.4 Volba vhodných multiplikátorů

Před samotným oceněním společnosti je důležité zvolit vhodný multiplikátor pro stanovení hodnoty společnosti tak, aby měl správnou vypovídací hodnotu. A. Damodaran (2018) rozebírá společnosti podle životního cyklu a podle specifických druhů společností pro jednodušší orientaci při výběru multiplikátorů.

Tab. 1: Volba vhodných multiplikátorů podle životního cyklu společnosti

	Ziskové	Výnosové	Založené na účetní hodnotě	Jiné
Start-up		×		
Rozvíjející se společnost	×	×		
Vyspělá společnost	×	×	×	
Společnost v úpadku				×

Zdroj: vlastní zpracování (Damodaran, 2018).

Tab. 2: Volba vhodných multiplikátorů podle druhu společnosti

	Ziskové	Výnosové	Založené na účetní hodnotě	Jiné
Cyklická či komoditní společnost	×	×		
Kapitálově náročné společnosti			×	
Finanční instituce	×		×	
Společnost jejíž hodnota je tvořena nehmotným majetkem				×

Zdroj: vlastní zpracování (Damodaran, 2018).

2.5 Metoda multiplikátorů a její omezení

Jsou určité skutečnosti, na které multiplikátory neberou ohled. Například na rozdíl od metody DCF multiplikátory neuvažují důležitost managementu, nejmodernější inovace a technologie, či jiné skutečnosti, které mají důležitou vazbu na ocenění (Berk – DeMarzo, 2014). Ačkoli se setkáme s mnoha názory ohledně minimálních subjektivních zásahů u metody multiplikátorů, řada z nich zde je a výslednou hodnotu ocenění společnosti mohou výrazně ovlivnit. Pokud například oceňuje společnost analytik, který stojí na straně kupujícího, pak může pro ocenění použít forward multiplikátory, jejichž hodnota se od current nebo trailing multiplikátorů může výrazně lišit (např. Dechow – Hutton – Sloan, 2000 a Groyberg – Healy – Chapman, 2008). Podobné dopady subjektivního rozhodování uvádí Pratt (2005), podle něhož máme hodnotu multiplikátorů upravovat procentuálně nahoru či dolu v případě odlišnosti od srovnatelných společností, pokud například srovnatelné společnosti drží finanční prostředky v podstatně jiné míře než oceňovaná společnost (také Henschke – Homburg, 2009). Dalšími problémy může být, pokud oceňovaná společnost nepůsobí 100% v jednom odvětví a je třeba každému odvětví přiřadit určitou váhu. Zde je ale potřeba zmínit, že výběr srovnatelných společností je zásadní se značným dopadem na výsledné ocenění, proto je doporučováno volit takové společnosti, které mají velmi podobnou strukturu výnosů, zdroje růstu a rizik k oceňované společnosti. Dalším omezením může také být umělé nadhodnocení odvětvového multiplikátoru při vyřazení neziskových společností z jeho výpočtu.

2.6 Testování metody odvětvových multiplikátorů

Mezi jedny z hlavních průkopníků v oblasti testování metody multiplikátorů patří Lie a Lie (2002), kteří uvádí, že větší společnosti vykazují daleko přesnější výsledky než malé a střední společnosti, ocenění je přesnější pro nefinanční instituce a zároveň nejméně přesné pro společnosti s vysokým zastoupením nehmotných aktiv (především společnosti působící v online prostředí). Dle Andrew W. Alford (1992) záleží na volbě odvětvové klasifikace pro dosažení přesnějšího výsledku při použití multiplikátorů. Yoo (2006) či Deng, Easton a Yeo (2010) dokonce přichází s oceňováním společností při kombinaci multiplikátorů namísto jejich samotného použití vyústějící v přesnější ocenění společností.

3. Předmět a metodický postup analýzy

3.1 Zkoumané společnosti a zdroj finančních dat

Pro zkoumání jsou zvoleny společnosti obchodované na amerických kapitálových trzích vzhledem k dostupnosti dat, které jsou vynucovány Security Exchange Commission (SEC). Americký kapitálový trh lze také považovat za fundamentální, monitorovaný světovými subjekty, jehož aktivita má globální dopad. Dalším kritériem výběru byl nezáporný výsledek hospodaření v letech 2010-2019. Vzorek vyústil v 1 266 společností, které jsou zkoumány v letech 2010-2019 pro vyhnutí se sezónností, letům 2008 a 2009, vzhledem k dopadům ekonomické krize, a také roku 2020, na který měla vliv pandemie COVID-19.

Zdrojem finančních dat je databáze S&P Capital IQ (2021), která slouží především finančním analytikům k práci s daty. Dále je využito multiplikátorů zveřejněných A. Damodaranem, taktéž v letech 2010-2019, na jeho webových stránkách (Damodaran, 2021).

Tab. 3: Popisná statistika zkoumaných společností

	Průměr	Medián	Min	Max	#
Tržby (v mil. \$)	6 427,5	712,5	0,0	523 964,0	12 366
EBITDA (v mil. \$)	1 727,1	357,7	0,1	115 641,0	8 163
EBIT (v mil. \$)	1 288,7	257,4	0,1	105 577,0	8 350
VH (v mil. \$)	668,1	69,3	0,0	81 417,0	12 638
Aktiva (v mil. \$)	19 559,1	1 863,9	0,3	2 687 379,0	12 564
Tržní kapitalizace (v mil. \$)	13 265,6	1 726,5	2,1	1 304 764,8	11 745
EV (v mil. \$)	9 129,7	936,4	0,0	939 959,0	12 504
Vlastní kapitál (v mil. \$)	4 233,1	555,8	0,0	428 563,0	12 504

Pozn.: EBIT a EBITDA nejsou vykazovány finančními institucemi, proto je zde počet pozorování (#) nižší.

Zdroj: vlastní zpracování, databáze Capital IQ (2021).

3.2 Volba a výpočet multiplikátorů

Výběr konkrétních multiplikátorů vychází z praxí nejčastěji používaných dle následujícího členění:

- Entity – EV/EBITDA, EV/EBIT a EV/S,
- Equity – P/EPS, P/BV a P/S.

Způsob výpočtu proměnných vybraných multiplikátorů pro účely tohoto zkoumání je určen následovně:

- P – cena akcie z kapitálového trhu k 1. 4. roku následujícího po roce, ke kterému je uvažována proměnná ve jmenovateli, dle Maříka (2018) je použita cena uzavírací k danému dni.
- EV – cena akcie viz výše vynásobená počtem akcií k danému dni, následně navýšená o účetní hodnotu úročeného cizího kapitálu ve stavu k 31. 12. roku předcházejícího.

- EBIT – výsledek hospodaření před zdaněním k 31.12. roku předcházejícího (pro společnosti, které fungují na bázi hospodářského roku se jedná o agregaci položek za uplynulých 12 měsíců k tomuto datu) zvýšený o nákladové úroky.
- EBITDA – EBIT navýšený o odpisy.
- EPS – výsledek hospodaření po zdanění vydělený počtem akcií k datu získání ceny akcie.
- BV – účetní hodnota vlastního kapitálu vydělená počtem akcií.
- S – čisté tržby, v případě equity vydělené počtem akcií.

Pro každou sledovanou společnost jsou pak za každý rok spočteny jednotlivé multiplikátory. Záporné hodnoty multiplikátorů jsou vyřazeny z důvodu zavádějících výsledků analýzy, a také protože se v praxi záporné multiplikátory pro výpočet hodnoty společnosti neuvažují.

3.3 Stanovení hodnoty odvětvových multiplikátorů

Zkoumané společnosti jsou rozděleny do 11 sektorů a člení se do 128 odvětví stanovených klasifikací S&P 500. Pro větší vypovídací schopnost bylo zvoleno 21 odvětví, kde je zastoupeno alespoň 12 společností v každém odvětví. Po výpočtení multiplikátorů za každou společnost zvlášť za všechny sledované roky je stanoven odvětvový multiplikátor za jednotlivá odvětví pomocí mediánu a prostého aritmetického průměru. V následující tabulce jsou shrnuta zvolená odvětví a jejich multiplikátory (v prvním sloupci je uveden počet společností v odvětví).

Tab. 4: Popisná statistika odvětvových multiplikátorů

		Equity						Entity					
		P/EPS		P/BV		P/S		EV/EBIT		EV/EBITDA		EV/S	
Odvětví	#	Med.	Prům.	Med.	Prům.	Med.	Prům.	Med.	Prům.	Med.	Prům.	Med.	Prům.
Aerospace and Defense	17	20,2	27,4	2,8	8,0	1,6	2,0	6,7	9,1	5,5	5,7	0,9	1,0
Apparel	27	18,5	25,3	2,8	8,9	1,0	1,2	4,6	1,1	3,4	4,0	0,4	0,5
Application Software	20	33,7	74,2	3,9	6,6	4,2	4,8	7,0	6,1	5,5	7,1	1,3	1,4
Auto Parts	12	18,4	20,6	2,9	3,4	1,0	1,4	4,9	5,4	3,8	3,8	0,5	0,5
Automotive Retail	13	15,5	16,6	2,6	3,4	0,4	0,9	8,4	8,1	7,3	6,8	0,4	0,5
Consumer Finance	16	12,4	15,1	1,9	2,2	7,5	12,0	7,0	8,1	6,1	7,2	20,4	69,2
Data Processing and Outsourced Services	19	26,0	31,0	4,4	7,6	4,1	4,9	5,1	6,6	3,9	4,9	0,9	2,0
Electric Utilities	18	18,8	19,5	1,7	1,8	2,2	2,3	12,7	13,2	7,7	8,0	2,6	2,7
Electrical Components and Equipment	14	20,1	28,6	3,1	3,6	1,6	1,8	6,3	7,3	5,2	5,7	0,7	0,9
Health Care Equipment	20	28,1	43,5	3,8	-8,0	3,4	4,0	5,9	8,2	4,8	5,0	1,1	1,2
Industrial Machinery	35	21,2	30,2	3,1	4,0	1,7	2,1	6,2	7,0	4,9	5,2	0,8	0,8
Life and Health Insurance	13	11,2	13,6	0,9	1,1	1,3	1,5	10,6	13,7	9,7	11,3	1,8	2,0
Oil and Gas Exploration and Production	17	10,2	11,8	8,9	262,0	9,7	10,2	1,0	2,8	1,3	1,5	0,8	2,5
Packaged Foods and Meats	18	20,9	31,1	3,7	5,0	1,8	1,9	6,0	6,9	4,7	5,3	0,6	0,8
Property and Casualty Insurance	22	14,5	219,3	1,3	1,6	1,3	1,7	8,3	11,3	7,4	9,6	1,2	1,7
Regional Banks	346	14,1	16,4	1,2	1,3	14,9	22,0	N/A	N/A	N/A	N/A	20,1	30,7
Restaurants	23	21,9	34,6	3,5	9,4	1,4	1,8	4,8	6,2	3,2	3,9	0,5	0,5
Semiconductor	12	24,8	33,1	3,8	4,8	4,5	5,5	5,8	7,0	4,8	5,1	1,3	1,5
Specialty Chemicals	19	20,4	27,5	3,3	4,6	1,9	2,0	6,8	8,0	5,1	5,6	0,8	1,0
Thriffs and Mortgage Finance	50	15,8	21,7	1,1	1,2	22,0	97,3	N/A	N/A	N/A	N/A	35,2	98,1
Trading Companies and Distributors	14	18,5	21,9	2,3	3,0	1,3	1,5	8,4	10,3	6,6	7,4	0,5	1,9

Zdroj: vlastní zpracování, databáze Capital IQ (2021).

Vysvětlivky: Aerospace and Defense = Letectví a obrana, Apparel = Oděvnictví, Application Software = Aplikovaný software, Auto Parts = Autodíly. Automotive Retail = Automobilový maloobchod, Consumer Finance = Spotřebitelské finance, Data Processing and Outsourced Services = Zpracování dat a outsourcované služby, Electric Utilities = Elektrárenské podniky, Electrical Components and Equipment = Elektrické součástky a zařízení, Health Care Equipment = Zdravotnické vybavení, Industrial Machinery = Průmyslové stroje, Life and Health Insurance = Životní a zdravotní pojištění, Oil and Gas Exploration and Production = Průzkum a těžba ropy a zemního plynu, Packaged Foods and Meats = Balená jídla a maso, Property and Casualty Insurance = Pojištění majetku a odpovědnosti, Regional Banks = Regionální banky, Restaurants = Restaurace, Semiconductor = Polovodiče, Specialty Chemicals = Speciální chemikálie, Thriffs and Mortgage Finance = Spořitelny a hypoteční financování, Trading Companies and Distributors = Obchodní společnosti a distributoři.

3.4 Výpočet odchylek

Po vypočtení multiplikátorů jednotlivých společností a stanovení hodnoty odvětvových multiplikátorů následuje výpočet odchylek. Velikost odchylky je dána porovnáním hodnoty stanovených multiplikátorů za celé odvětví s jednotlivými multiplikátory sledovaných společností za každý rok zvlášť. Výsledné odchylky udávají, jak podhodnocené či nadhodnocené multiplikátory společností jsou, a jak daleko se nachází od mediánu/průměru odvětví. Finální výpočet odchylek se také odvíjí od samotného způsobu výpočtu odchylky a stanovení střední hodnoty odchylek. Způsob stanovení odchylek následuje metodologii autorů Lie a Lie (2002), Eberhart (2004) či Kaplan a Ruback (1995), kteří testují hodnoty multiplikátorů relativním způsobem:

$$\text{Chyba ocenění} = \ln\left(\frac{M_O}{M}\right), \quad (1)$$

kde M_O – multiplikátor odvětví,
 M – multiplikátor dané společnosti v daném roce.

Pro účely tohoto článku je uvažováno pouze s velikostí odchylky v absolutní výši, jelikož jde především o zkoumání přesnosti ocenění. Střední hodnota odchylek je stanovena na základě aritmetického průměru, do kterého jsou zahrnuty všechny chyby ocenění v daném odvětví.

Odchylyky ocenění jsou zkoumány z řady pohledů na základě provedené rešerše a jsou následující:

- Dle velikosti společností – společnosti jsou rozděleny do kategorií podle výše obratu, cílem je zjistit výši odchylek v porovnání malých, středních a velkých společností.
- Dle odvětví – zde jsou společnosti rozděleny do zvolených odvětví, cílem je porovnat přesnost multiplikátorů stanovených pomocí mediánu či průměru, entity nebo equity a jednotlivých multiplikátorů pro účely zjištění nejvhodnějšího odvětvového multiplikátoru.
- Dle multiplikátorů Damodarana (2021) – zkoumání navazuje na předchozí část při porovnání stanovených multiplikátorů s hodnotami multiplikátorů Damodarana (2021). Cílem je poukázat na přesnost ocenění při použití multiplikátorů Damodarana, pro stejné jednotlivé roky jako byly šetřeny ve vzorku společností, v porovnání s vlastními vytvořenými multiplikátory.
- Dle největších společností v odvětví – zde jsou uvažovány tři největší společnosti v odvětví v porovnání s celým odvětvím, cílem šetření je poukázat, zda multiplikátory větších společností v odvětví dosahují vyšších hodnot než multiplikátory celého odvětví.
- Dle vývoje v čase – závěrem jsou zkoumány dle odvětví absolutní výše multiplikátorů v jednotlivých letech.

4. Odchylyky ocenění při použití vlastních odvětvových multiplikátorů

4.1 Odchylyky dle velikosti společností

Společnosti jsou rozděleny na malé, střední a velké. Malé společnosti spadají do skupiny s obratem nižším než 100 mil. \$, střední do rozmezí s obratem 100 mil. \$ až 3 mld. \$ a velké jsou ty, které mají obrat vyšší. V následující tabulce jsou vypočtené odchylyky pro jednotlivé multiplikátory členěné dle stanovených skupin.

Tab. 5: Odchylyky multiplikátorů dle velikosti společností

	P/EPS	P/BV	P/S	EV/EBIT	EV/EBITDA	EV/S
<i>A. Malé společnosti s obratem ≤ 100 mil. \$</i>						
Medián	−0,4 %	1,7 %	−11,2 %	15,5 %	−6,8 %	−11,7 %
Průměr	20,8 %	27,5 %	38,2 %	46,8 %	8,9 %	38,3 %
#	3 353	3 330	3 253	679	496	3 872
<i>B. Střední společnosti s obratem 100 mi. \$ ≤ 3 mld. \$</i>						
Medián	−9,3 %	−2,6 %	5,9 %	−5,7 %	−2,5 %	4,7 %
Průměr	24,2 %	26,7 %	29,4 %	8,8 %	8,9 %	28,4 %
#	4 325	4 316	4 309	3 720	3 719	4 373
<i>C. Velké společnosti s obratem < 3 mld. \$</i>						
Medián	−3,2 %	−19,8 %	2,2 %	2,3 %	3,1 %	−0,6 %
Průměr	33,0 %	17,3 %	20,3 %	12,3 %	13,5 %	15,3 %
#	4 035	4 034	4 035	3 940	3 937	4 090

Zdroj: vlastní zpracování, databáze Capital IQ (2021).

Z tabulky je na první pohled patrné, že medián je pro určení hodnoty multiplikátorů jednoznačně přesnější. Jediným rozdílem je multiplikátor P/BV u velkých společností, kde je přesnější průměr, avšak nepatrně. Pokud tedy uvažujeme medián, jakožto přesnější metodu stanovení hodnoty odvětvových multiplikátorů, pak pouze multiplikátory P/S s chybou ocenění 2,2 %, EV/EBIT s chybou ocenění 2,3 % a EV/S s chybou ocenění ve výši pouze −0,6 % odhalují, že jsou multiplikátory velkých společností přesnější než multiplikátory společností menších. V případě EV/EBITDA s hodnotou −2,5 % jsou přesnější u středních společností a P/EPS a P/BV u malých společností.

4.2 Odchylyky dle odvětví

Rozdělení společností do jednotlivých odvětví nám pomáhá najít srovnatelné společnosti k oceňovanému podniku, a tedy stanovit konkrétní odvětvový multiplikátor, viz Tab. 4:. V Tab. 6: jsou vypočteny odchylyky po odvětvích, zde už v některých případech dosahují hodnoty odchylek 100 % a výše, což je způsobeno vysokými výkyvy ve výpočtech multiplikátorů při použití průměru. Nejvyšší přesnost udává multiplikátor EV/EBIT u odvětví Industrial Machinery, a to dokonce 100%. Takové skutečnosti lze v praxi dosáhnout jen velmi zřídka, jelikož se jedná o metodu srovnávací a naleznout na trhu plně identickou společnost je takřka nemožné. Z výsledků vyplývá, že až na jediné tři výsledky medián jednoznačně předčil hodnoty průměru, a tedy vykazuje daleko přesnější výsledky. Použijeme-li opět medián pro stanovení odchylyky samotných odvětví, tak při použití všech multiplikátorů vykazují nejlepší výsledky odvětví Electric Utilities s hodnotou 1,5 % následované Industrial Machinery s 2,9 % a Auto Parts s 3,2 %.

Tab. 6: Odchytky odvětvových multiplikátorů

Odvětví	Equity						Entity					
	P/EPS		P/BV		P/S		EV/EBIT		EV/EBITDA		EV/S	
	Med.	Prům.	Med.	Prům.	Med.	Prům.	Med.	Prům.	Med.	Prům.	Med.	Prům.
Aerospace and Defense	-8,7 %	22,0 %	-18,9 %	85,8 %	-1,1 %	20,1 %	-5,3 %	26,0 %	2,5 %	6,5 %	2,6 %	15,1 %
Apparel	-6,5 %	24,9 %	-13,4 %	102,9 %	2,1 %	16,5 %	-0,5 %	140,6 %	-0,2 %	14,3 %	-3,0 %	8,2 %
Application Software	-10,7 %	68,2 %	-16,3 %	35,3 %	3,0 %	16,0 %	-3,4 %	-18,2 %	1,7 %	26,9 %	9,2 %	16,4 %
Auto Parts	7,8 %	19,1 %	-2,8 %	13,3 %	-2,0 %	32,6 %	-1,2 %	9,5 %	1,3 %	2,1 %	-4,1 %	8,7 %
Automotive Retail	1,0 %	7,7 %	-11,4 %	17,0 %	-21,8 %	52,0 %	19,4 %	16,1 %	23,3 %	16,5 %	-3,5 %	11,8 %
Consumer Finance	-3,2 %	16,5 %	-0,3 %	15,2 %	13,0 %	59,9 %	-4,1 %	10,2 %	-6,7 %	10,1 %	51,2 %	173,4 %
Data Processing and Out. Servic.	-4,0 %	13,7 %	-18,6 %	36,3 %	4,9 %	23,4 %	1,9 %	26,1 %	-2,9 %	20,4 %	-24,2 %	48,2 %
Electric Utilities	0,2 %	3,6 %	1,4 %	2,8 %	2,9 %	7,3 %	-1,1 %	2,8 %	-2,9 %	1,8 %	-0,6 %	5,1 %
Electrical Components and Eq.	-4,4 %	30,9 %	3,1 %	19,6 %	3,4 %	13,5 %	-5,7 %	8,6 %	-3,5 %	5,8 %	-6,9 %	7,3 %
Health Care Equipment	-1,3 %	42,4 %	-0,2 %	-263,6 %	11,4 %	27,0 %	-7,6 %	25,0 %	-0,5 %	4,0 %	6,5 %	13,6 %
Industrial Machinery	-4,4 %	30,9 %	-6,0 %	18,0 %	-0,7 %	21,5 %	0,0 %	11,6 %	2,1 %	6,6 %	4,3 %	8,4 %
Life and Health Insurance	-5,9 %	13,5 %	-4,3 %	11,4 %	-1,4 %	15,5 %	-3,5 %	21,4 %	-4,7 %	10,7 %	-2,4 %	9,5 %
Oil and Gas Explor. and Prod.	10,5 %	24,9 %	-49,3 %	289,2 %	8,1 %	13,2 %	49,5 %	149,0 %	7,1 %	17,3 %	50,4 %	160,2 %
Packaged Foods and Meats	-1,8 %	37,7 %	-3,5 %	25,6 %	12,8 %	15,4 %	1,1 %	15,9 %	-0,6 %	12,0 %	-9,1 %	15,2 %
Property and Casualty Insurance	-12,6 %	259,3 %	-5,9 %	15,2 %	-7,8 %	16,5 %	-9,8 %	21,6 %	-9,4 %	17,2 %	-9,8 %	28,3 %
Regional Banks	-3,4 %	11,6 %	1,0 %	6,4 %	-6,6 %	32,0 %	N/A	N/A	N/A	N/A	-9,5 %	32,6 %
Restaurants	-7,4 %	38,1 %	-29,6 %	69,4 %	-0,5 %	27,8 %	-2,3 %	23,9 %	-4,3 %	14,6 %	0,4 %	12,2 %
Semiconductor	-8,0 %	20,8 %	-10,8 %	12,8 %	-6,0 %	13,9 %	-5,1 %	14,0 %	3,0 %	8,3 %	-8,4 %	7,7 %
Specialty Chemicals	-8,5 %	21,2 %	-11,6 %	21,6 %	4,3 %	13,8 %	4,0 %	19,8 %	2,2 %	12,6 %	-2,5 %	16,6 %
Thriffs and Mortgage Finance	-10,7 %	20,7 %	-0,8 %	6,8 %	-8,5 %	140,1 %	N/A	N/A	N/A	N/A	-9,2 %	93,4 %
Trading Companies and Distr.	4,8 %	21,8 %	1,1 %	28,6 %	23,0 %	39,6 %	4,3 %	25,2 %	6,6 %	19,1 %	-47,4 %	85,0 %

Zdroj: vlastní zpracování, databáze Capital IQ (2021).

Dle odchylek ocenění u odvětvových multiplikátorů lze dále určit, které multiplikátory jsou vhodnější při použití průměru a které při mediánu. Z následující tabulky vyplývá, že při použití průměru je nejvhodnější použít multiplikátor EV/EBITDA. U mediánu je to pak multiplikátor P/BV následovaný také EV/EBITDA. Vhodnost ukazatele P/BV není v praxi velmi běžná, i když výsledky korelují s prací Lie a Lie (2002), kteří také dospěli k vyšší přesnosti tohoto ukazatele. Takové zjištění naopak rozporují studie Liu, Nissim a Thomas (2002) a Baker a Ruback (1999), kteří tyto multiplikátory staví spíše na spodní příčky dle jejich přesnosti. Co se týče multiplikátorů dle typu, pak u průměru převládají entity multiplikátory a u mediánu, ač nepatrně, equity multiplikátory. Za zmínku stojí finanční instituce, které ve všech případech ukazují na P/BV multiplikátor jakožto nejpřesnější.

Tab. 7: Přehled odvětvových multiplikátorů z hlediska přesnosti ocenění

Odvětví	Medián	Průměr
Aerospace and Defense	P/S	EV/EBITDA
Apparel	EV/EBITDA	EV/S
Application Software	EV/EBITDA	P/S
Auto Parts	EV/EBIT	EV/EBITDA
Automotive Retail	P/EPS	P/EPS
Consumer Finance	P/BV	EV/EBITDA
Data Processing and Outsourced Services	EV/EBIT	P/EPS
Electric Utilities	P/EPS	EV/EBITDA
Electrical Components and Equipment	P/BV	EV/EBITDA
Health Care Equipment	P/BV	EV/EBITDA
Industrial Machinery	EV/EBIT	EV/EBITDA
Life and Health Insurance	P/S	EV/S
Oil and Gas Exploration and Production	EV/EBITDA	P/S
Packaged Foods and Meats	EV/EBITDA	EV/EBITDA
Property and Casualty Insurance	P/BV	P/BV
Regional Banks	P/BV	P/BV
Restaurants	EV/S	EV/S
Semiconductor	EV/EBITDA	EV/S
Specialty Chemicals	EV/EBITDA	EV/EBITDA
Thriffs and Mortgage Finance	P/BV	P/BV
Trading Companies and Distributors	P/BV	EV/EBITDA

Zdroj: vlastní zpracování, databáze Capital IQ (2021).

4.3 Odchyly dle multiplikátorů Damodarana

Odchyly dle odvětví jsou zde dále rozšířeny o světově uznávané a běžně používané odvětvové multiplikátory A. Damodarana (2021) v porovnání s vybraným vzorkem společností. Damodaran uvažuje v každém odvětví podstatně větší množství společností než ve vybraném vzorku, viz tabulka níže. Členění odvětví je v některých případech rozdílné, ačkoli je v obou případech zkoumání postaveno na stejné klasifikaci. Na první pohled je zřejmé, že se multiplikátory liší. Největší rozdíly jsou patrné u multiplikátoru EV/EBITDA, kdy u Damodarana ve většině případů dosahuje dvouciferných čísel.

Tab. 8: Porovnání odvětvových multiplikátorů vzorku a Damodarana

Odvětví	Medián vzorku společností				Multiplikátor dle Damodarana			
	#	P/BV	EV/EBITDA	EV/S	#	P/BV	EV/EBITDA	EV/S
Aerospace and Defense	17	2,8	5,5	0,9	82	4,3	10,8	1,6
Apparel	27	2,8	3,4	0,4	57	3,5	12,1	1,9
Application Software	20	3,9	5,5	1,3	285	5,9	22,6	6,1
Auto Parts	12	2,9	3,8	0,5	59	2,4	7,0	0,8
Automotive Retail	13	2,6	7,3	0,4	24	5,3	12,2	0,9
Consumer Finance	16	1,9	6,1	20,4	N/A	N/A	N/A	N/A
Data Processing and Outsourced Services	19	4,4	3,9	0,9	N/A	N/A	N/A	N/A
Electric Utilities	18	1,7	7,7	2,6	N/A	N/A	N/A	N/A
Electrical Components and Equipment	14	3,1	5,2	0,7	106	3,8	12,5	2,1
Health Care Equipment	20	3,8	4,8	1,1	224	3,8	15,4	3,8
Industrial Machinery	35	3,1	4,9	0,8	122	3,3	12,2	1,8
Life and Health Insurance	13	0,9	9,7	1,8	26	0,9	9,9	1,3
Oil and Gas Exploration and Production	17	8,9	1,3	0,8	338	1,3	7,7	3,1
Packaged Foods and Meats	18	3,7	4,7	0,6	N/A	N/A	N/A	N/A
Property and Casualty Insurance	22	1,3	7,4	1,2	54	1,3	12,4	1,4
Regional Banks	346	1,2	N/A	20,1	649	1,3	N/A	5,4
Restaurants	23	3,5	3,2	0,5	76	7,7	12,4	3,0
Semiconductor	12	3,8	4,8	1,3	98	3,4	10,3	3,2
Specialty Chemicals	19	3,3	5,1	0,8	91	3,6	11,4	2,2
Thriffs and Mortgage Finance	50	1,1	N/A	35,2	238	1,9	14,6	29,6
Trading Companies and Distributors	14	2,3	6,6	0,5	N/A	N/A	N/A	N/A

Zdroj: vlastní zpracování, databáze Capital IQ (2021), Damodaran (2021).


Stejně jako rozdíl výše multiplikátoru EV/EBITDA se i odchyly tohoto ukazatele u Damodarana podstatně liší, podobná situace nastává u multiplikátoru EV/S, viz následující tabulka. Pouze v sedmi případech vykazují multiplikátory Damodarana přesnější výsledky než multiplikátory vzorku společností.

Následující grafy ukazují rozdělení odchylek sledovaných multiplikátorů v rozmezí menší než –100 % až větší než 100 %. Grafy nepracují s průměrnou mírou chybovosti jako tomu bylo doposud, ale se všemi odchylkami pro dané multiplikátory ve všech sledovaných odvětvích za 10 let. První graf poukazuje na rozdělení tří zvolených multiplikátorů vzorku společností. Chybovost v zásadě kopíruje normální rozdělení, a tedy, že největší zastoupení se pohybuje okolo 0 %, což odpovídá vysoké míře přesnosti. Takový případ nastává hlavně u multiplikátorů P/BV a EV/EBITDA. U multiplikátoru EV/S se míra chybovosti přelívá do extrémních hodnot. Další graf demonstruje pravděpodobnostní rozdělení přesnosti multiplikátorů Damodarana. Zde pouze multiplikátor P/BV do jisté míry kopíruje plynulý průběh normálního rozdělení. Multiplikátory EV/S a EV/EBITDA jsou z větší části odsunuty do extrémních hodnot.


Tab. 9: Odchyly odvětvových multiplikátorů vzorku a Damodarana

Odvětví	Vzorek společností			Damodaran		
	P/BV	EV/EBITDA	EV/S	P/BV	EV/EBITDA	EV/S
Aerospace and Defense	-18,9 %	2,5 %	2,6 %	23,6 %	70,5 %	64,2 %
Apparel	-13,4 %	-0,2 %	-3,0 %	9,2 %	125,2 %	146,0 %
Application Software	-16,3 %	1,7 %	9,2 %	24,1 %	142,9 %	164,2 %
Auto Parts	-2,8 %	1,3 %	-4,1 %	-18,6 %	63,0 %	54,2 %
Automotive Retail	-11,4 %	23,3 %	-3,5 %	60,8 %	74,3 %	83,5 %
Consumer Finance	-0,3 %	-6,7 %	51,2 %	N/A	N/A	N/A
Data Processing and Outsourced Services	-18,6 %	-2,9 %	-24,2 %	N/A	N/A	N/A
Electric Utilities	1,4 %	-2,9 %	-0,6 %	N/A	N/A	N/A
Electrical Components and Equipment	3,1 %	-3,5 %	-6,9 %	23,7 %	84,5 %	95,0 %
Health Care Equipment	-0,2 %	-0,5 %	6,5 %	-0,4 %	115,8 %	129,3 %
Industrial Machinery	-6,0 %	2,1 %	4,3 %	-1,8 %	92,1 %	86,5 %
Life and Health Insurance	-4,3 %	-4,7 %	-2,4 %	-6,1 %	-2,2 %	-31,3 %
Oil and Gas Exploration and Production	-49,3 %	7,1 %	50,4 %	-237,9 %	183,5 %	181,9 %
Packaged Foods and Meats	-3,5 %	-0,6 %	-9,1 %	N/A	N/A	N/A
Property and Casualty Insurance	-5,9 %	-9,4 %	-9,8 %	-2,4 %	42,1 %	9,3 %
Regional Banks	1,0 %	N/A	-9,5 %	6,3 %	N/A	-140,2 %
Restaurants	-29,6 %	-4,3 %	0,4 %	49,4 %	131,2 %	186,8 %
Semiconductor	-10,8 %	3,0 %	-8,4 %	-22,6 %	78,3 %	79,9 %
Specialty Chemicals	-11,6 %	2,2 %	-2,5 %	-3,7 %	82,6 %	96,1 %
Thriffs and Mortgage Finance	-0,8 %	N/A	-9,2 %	56,4 %	N/A	-26,6 %
Trading Companies and Distributors	1,1 %	6,6 %	-47,4 %	N/A	N/A	N/A

Zdroj: vlastní zpracování, databáze Capital IQ (2021), Damodaran (2021).

Obr. 1: Rozdělení odchylek ocenění vzorku společností

Zdroj: vlastní zpracování, databáze Capital IQ (2021).

Obr. 2: Rozdělení odchylek ocenění Damodaran

Zdroj: vlastní zpracování, databáze Capital IQ (2021), Damodaran (2021).

Hlavní důvody, které mohou vést k takto velkým rozdílům mezi multiplikátory sestavenými na základě vzorku společností a multiplikátory Damodarana, jsou následovné:

- Způsob výpočtu – Damodaran sestavuje multiplikátory agregací multiplikátorů v odvětví. Nikde přesně neuvádí, jakým způsobem jednotlivé proměnné zjišťuje a co do nich zahrnuje. Do výpočtu zahrnuje i společnosti se záporným výsledkem hospodaření.
- Okamžik výpočtu – Damodaran počítá multiplikátory vždy k 1.1. daného roku.
- Sledované roky – Damodaran počítá multiplikátory na roční bázi.
- Počet zkoumaných společností – Damodaran uvažuje daleko více společností v odvětví.

4.4 Odchyly dle největších společností v odvětví

Odchyly dle největších společností v odvětví již neuvažují odchylky ocenění, nýbrž absolutní výši multiplikátorů v porovnání tří největších společností v odvětví ku celému odvětví, viz následující tabulka. Porovnáme-li jednotlivé multiplikátory, lze vyvodit závěr, že největší společnosti v odvětví jednoznačně nevykazují vyšší hodnoty než multiplikátory celého odvětví.

Tab. 10: Odvětvové multiplikátory největších společností v odvětví


Odvětví	Medián vzorku společností				Medián 3 největších společností z odvětví		
	#	P/BV	EV/EBITDA	EV/S	P/BV	EV/EBITDA	EV/S
Aerospace and Defense	17	2,8	5,5	0,9	3,9	3,7	0,6
Apparel	27	2,8	3,4	0,4	9,0	1,5	0,2
Application Software	20	3,9	5,5	1,3	6,2	5,1	1,7
Auto Parts	12	2,9	3,8	0,5	2,3	3,8	0,4
Automotive Retail	13	2,6	7,3	0,4	2,6	10,5	0,4
Consumer Finance	16	1,9	6,1	20,4	1,9	4,0	3,1
Data Processing and Outsourced Services	19	4,4	3,9	0,9	9,3	2,6	0,9
Electric Utilities	18	1,7	7,7	2,6	1,4	7,8	2,7
Electrical Components and Equipment	14	3,1	5,2	0,7	4,6	3,8	0,8
Health Care Equipment	20	3,8	4,8	1,1	2,7	8,2	2,0
Industrial Machinery	35	3,1	4,9	0,8	2,9	5,0	0,9
Life and Health Insurance	13	0,9	9,7	1,8	1,2	8,9	1,7
Oil and Gas Exploration and Production	17	8,9	1,3	0,8	31,7	1,3	0,7
Packaged Foods and Meats	18	3,7	4,7	0,6	2,4	5,8	1,0
Property and Casualty Insurance	22	1,3	7,4	1,2	1,5	5,4	0,8
Regional Banks	346	1,2	N/A	20,1	1,1	N/A	12,8
Restaurants	23	3,5	3,2	0,5	5,4	2,9	0,6
Semiconductor	12	3,8	4,8	1,3	3,5	3,4	1,2
Specialty Chemicals	19	3,3	5,1	0,8	5,4	4,7	0,7
Thriffs and Mortgage Finance	50	1,1	N/A	35,2	1,4	N/A	5,1
Trading Companies and Distributors	14	2,3	6,6	0,5	1,7	7,6	0,4

Zdroj: vlastní zpracování, databáze Capital IQ (2021).

4.5 Odchyly dle vývoje v čase


Poslední zkoumání se zabývá vývojem odvětvových multiplikátorů v čase. Zkoumány jsou zde pouze multiplikátory P/BV a EV/EBITDA. V následujících grafech vidíme rozdělení multiplikátorů dle jednotlivých odvětví a jejich vývoj ve sledovaných letech 2010-2019. V některých případech se vývoj multiplikátorů liší pouze v rozmezí 0,5-2,0. V opačném případě jsou výkyvy vysoké, dané především extrémními hodnotami ve vzorku. Za zmínku stojí u P/BV odvětví Oil and Gas Exploration and Production, kde se vývoj multiplikátoru pohybuje v rozmezí 4,6 až 30,9. Nejnižšího rozmezí pak dosahuje Life and Health Insurance s vývojem 0,7-1,2. U EV/EBITDA nejvyšší rozmezí uvádí odvětví Property and Casualty Insurance 6,0-12,2 a nejnižší, v tomto případě opačně, Oil and Gas Exploration and Production 1,1-2,0.

Obr. 3: Vývoj multiplikátorů P/BV



Zdroj: vlastní zpracování, databáze Capital IQ (2021).

Obr. 4: Vývoj multiplikátorů EV/EBITDA



Zdroj: vlastní zpracování, databáze Capital IQ (2021).

Závěr

Metoda odvětvových multiplikátorů je v současné době velmi diskutovaným tématem a denním chlebem mnoha subjektů, které dnes a denně pracují s daty na kapitálových trzích. Mimo oceňování společností slouží multiplikátory k hodnocení jejich výkonnosti, strategickému rozhodování či k tzv. benchmarkingu. Na druhou stranu je metoda často kritizována, především z hlediska nepřesnosti a vysoké rozlišnosti výsledků při současném použití alternativních oceňovacích metod. Oceňování společností je v oboru financí důležitou disciplínou, a tedy je důležité, aby byly zkoumány i další metody oceňování a tento obor se nadále rozšiřoval.

Cílem tohoto článku bylo stanovit vlastní hodnoty šesti nejčastěji používaných multiplikátorů pro americký trh, zvláště pro medián a zvláště pro aritmetický průměr, a následně pro účely vhodnosti případného použití zjistit odchyly u těchto hodnot z hlediska velikosti společnosti, odvětví, velikosti společnosti v odvětví, času a vůči hodnotám Damodaranových multiplikátorů a navázat tak na již provedené empirické studie. Na celkem 1 266 amerických společnostech analyzovaných v letech 2010-2019 bylo demonstrováno, jaké odchyly ocenění by společnosti dosahovaly v případě vytvoření vlastních odvětvových multiplikátorů. Z výsledků provedených zkoumání lze shrnout, že je vhodnější použít medián odvětvových multiplikátorů namísto prostého aritmetického průměru, metoda multiplikátorů pro větší společnosti není jednoznačně přesnější, entity a equity multiplikátory také neukazují jednoznačné výsledky z hlediska přesnosti, u finančních institucí je však nejpřesnější multiplikátor P/BV ve všech případech. Dále pokud použijeme vlastní multiplikátory, lze dosáhnout vyšší přesnosti než při použití multiplikátorů od Damodarana, přičemž přístup k sestavení multiplikátorů se zde od jeho přístupu výrazně liší. Multiplikátory větších společností v odvětví nedosahují přesvědčivě vyšších hodnot než medián odvětví a na závěr vývoj multiplikátorů v čase se výrazně liší, proto není vhodné využít multiplikátor zkonstruovaný pouze z dat jednoho roku.

Provedená empirická studie má řadu omezení, může být rozšířena o hlavní determinanty vývoje multiplikátorů podložené regresní analýzou, nahrazení průměru a mediánu harmonickým průměrem, který na základě empirie přináší přesnější výsledky či dokonce využít forward multiplikátory. Zároveň může být výzkum doplněn o statistické šetření dokazující výsledky provedené analýzy, tomu se autoři budou věnovat v další publikaci.

Literatura:

- [1] ALFORD, A. W. (1992): The Effect of the Set of Comparable Firms on the Accuracy of the Price-Earnings Valuation Method. *Journal of Accounting Research*, 1992, roč. 30, č. 1, s. 94-108.
- [2] BAKER, M. – RUBACK, R. S. (1999): Estimating Industry Multiples. [online]. Cambridge, Harvard Business School, 1999, [cit. 10. 4. 2021], <<https://www.hbs.edu/faculty/Pages/download.aspx?name=EstimatingIndustry.pdf>>.
- [3] BERK, J. – DEMARZO, P. (2014): Corporate Finance. Stanford, Stanford University / Pearson Education, 2014. ISBN 978-0-13-299247-3.
- [4] BUDSKÝ, P. – Dvořák, J. (2017): Průměrné multiplikátory odvětví a jejich komparace s daty z burzy. *Oceňování*, 2017, roč. 10, č. 4, s. 3-13.
- [5] Capital IQ (2021): S&P Capital IQ Platform. [elektronický zdroj]. New York, S&P Global, 2021. Elektronická databáze.

- [6] DAMODARAN, A. (2018): *The Dark Side of Valuation. Valuing Young, Distressed, and Complex Businesses*. New York, Stern School of Business at New York University / Pearson FT Press, 2018. ISBN 978-0134854106.
- [7] DAMODARAN, A. (2021): Multiples – Enterprise Value Multiples by Sector (US). Multiples – PE Ratio by Sector (US). Multiples – Price and Value to Book Ratio by Sector (US). Multiples – Revenue Multiples by Sector (US). [online], New York, Stern School of Business at New York University, 2021, [cit. 10. 4. 2021], <<http://pages.stern.nyu.edu/~adamodar/>>
- [8] DECHOW, P. M. – HUTTON, A. P. – SLOAN, R. G. (2000): The Relation between Analysts' Forecasts of Long-Term Earnings Growth and Stock Price Performance Following Equity Offerings. *Contemporary Accounting Research*, 2000, roč. 17, č. 1, s. 1-32.
- [9] DEMIRAKOS, E. G. – STRONG, N. C. – WALKER, M. (2010): Does Valuation Model Choice Affect Target Price Accuracy? *European Accounting Review*, 2010, roč. 19, č. 1, s. 35-72.
- [10] DENG, M. – EASTON, P. – YEO, J. (2010): Another Look at Enterprise and Equity Valuation Based on Multiples. [online]. New York, Social Science Research Network, 2010, [cit. 10. 4. 2021], <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1462794>.
- [11] EBERHART, A. C. (2004): Equity Valuation Using Multiples. *Journal of Investing*, 2004, roč. 13, č. 2, s. 48-54.
- [12] GROYSBERG, B. – HEALY, P. – CHAPMAN, C. (2008): Buy-Side vs. Sell-Side Analysts' Earnings Forecasts. *Financial Analysts Journal*, 2008, roč. 64, č. 4, s. 25-39.
- [13] HENSCHKE, S. – HOMBURG, C. (2009): Equity Valuation Using Multiples: Controlling for Differences Between Firms. [online]. New York, Social Science Research Network, 2010, [cit. 10. 4. 2021], <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1270812>.
- [14] KAPLAN, N. S. – RUBACK, R. S. (1995): The Valuation of Cash Flow Forecasts: An Empirical Analysis. *Journal of Finance*, 1995, roč. 50, č. 4, s. 1059-1093.
- [15] KOLLER, T. – GOEDHART, M. – WESSELS, D. (2005): *Valuation Measuring and Managing the Value of Companies*. Hoboken, John Wiley & Sons, 2005. ISBN 978-0-471-70218-4.
- [16] LIE, E. – LIE, H. J. (2002): Multiples Used to Estimate Corporate Value. *Financial Analysts Journal*, 2002, roč. 58, č. 2, s. 44-54.
- [17] LIU, J. – NISSIM, D. – THOMAS, J. K. (2002): Equity Valuation Using Multiples. *Journal of Accounting Research*, 2002, roč. 40, č. 1, s. 135-172.
- [18] MAŘÍK, M. aj. (2018): *Metody oceňování podniku: proces ocenění, základní metody a postupy*. Praha, Ekopress, 2018. ISBN 978-80-87865-38-5.
- [19] NEL, W. S. – BRUWER, B. W. – le ROUX, N. J. (2013): Equity-And Entity-Based Multiples in Emerging Markets: Evidence from the JSE Securities Exchange. *Journal of Applied Business Research*, 2013, roč. 29, č. 3, s. 829-852.
- [20] SCHREINER, A. – SPREMANN, K. (2007): Multiples and Their Valuation Accuracy in European Equity Markets. [online]. New York, Social Science Research Network, 2007, [cit. 10. 4. 2021], <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=957352>.

- [21] YOO, Y. K. (2006): The valuation accuracy of equity valuation using a combination of multiples. *Review of Accounting and Finance*, 2006, roč. 5, s. 108-123.

Odchyšky ocenění při sestavení odvětvových multiplikátorů na amerických společnostech

Martin Husák – Petr Marek

ABSTRAKT

Vědecký článek je věnován problematice odvětvových multiplikátorů při oceňování společností z hlediska přesnosti. Pro analýzu bylo zvoleno 1 266 amerických společností obchodovaných na regulovaných kapitálových trzích v letech 2010-2019. Hlavním cílem je stanovit vlastní hodnoty šesti nejčastěji používaných multiplikátorů pro americký trh, zvlášť pro medián a zvlášť pro aritmetický průměr, a následně pro účely vhodnosti případného použití zjistit odchyšky u těchto hodnot z hlediska velikosti společnosti, odvětví, velikosti společnosti v odvětví, času a vůči hodnotám Damodaranových multiplikátorů. Provedená analýza ukazuje, že je vhodnější použít medián odvětvových multiplikátorů namísto prostého aritmetického průměru, metoda multiplikátorů pro větší společnosti není jednoznačně přesnější, entity a equity multiplikátory také neukazují jednoznačné výsledky z hlediska přesnosti. Pokud použijeme vlastní multiplikátory, lze dosáhnout vyšší přesnosti ocenění než při použití multiplikátorů Damodarana. Multiplikátory větších společností v odvětví nedosahují přesvědčivě vyšších hodnot než medián odvětví a také, že se vývoj multiplikátorů v čase výrazně liší.

Klíčová slova: Oceňování; Metoda tržního porovnání; Multiplikátory; Tržní násobky; Odchyšky ocenění; P/E; EV/EBITDA.

Valuation deviations in the compilation of industry multiples on American companies

ABSTRACT

The article is devoted to the issue of industry market multiples in valuing companies in terms of accuracy. A total of 1 266 US companies traded on regulated capital markets in 2010-2019 were selected for analysis. The main goal is to determine own values of the six most commonly used multiples for the US market, the median and the arithmetic average, and then to investigate deviations in these values in terms of company size, industry, company size in industry, time and values of Damodaran multiples. The analysis shows that it is more appropriate to use the median of industry multiples over a simple arithmetic average, the method of multiples for larger companies is not clearly more accurate, entity and equity multiples also do not show clear results in terms of accuracy. If we use our own industry multiples, it is possible to achieve higher accuracy of valuation than when using multiples of Damodaran. The multiples of the larger companies in the industry do not reach convincingly higher values than the median of the industry and also that the development of the multiples varies significantly over time.

Key words: Valuation; Market approach; Multiples; Market multiples; Valuation deviations; P/E; EV/EBITDA.

JEL classification: G32

Kvantifikace výnosnosti vlastního kapitálu Budějovického Budvaru při alternativní finanční struktuře – případová studie [#]

David Chudomský ^{} – Radana Šmídová ^{**}*

Úvod

Tato případová studie se zabývá aktuální a alternativní finanční strukturou společnosti Budějovický Budvar, n. p. (dál také „BB“). Cílem této studie je zjištění:

- zda BB historicky vytváří hodnotu pro vlastníky;
- namodelovat transakci, která by zvýšila výnosnost vlastního kapitálu („ROE“), ale přitom významně nezvýšila finanční riziko podniku;
- kvantifikovat jaké množství peněžních prostředků lze ze společnosti vlastníkem odebrat.

Zakladatelem podniku je Ministerstvo zemědělství České republiky, které tak za stát zastupuje roli zakladatele a vlastníka národního podniku. Předpokladem studie je, že i státem vlastněné podniky mají být řízeny efektivně se snahou maximalizovat hodnotu podniku.

Tato studie vychází z tradiční teorie nákladů kapitálu a z předpokladu, že náklady na vlastní kapitál jsou vyšší než na cizí kapitál. Prostou změnou finanční struktury tak lze snížit celkové náklady kapitálu a zvýšit tak hodnotu podniku. Nicméně, BB nemá žádné dluhové financování, a proto dle tradiční teorie nákladů kapitálu nemůže mít optimální kapitálovou strukturu, neboť nevyužívá levnějších cizích zdrojů, které ještě poskytují daňový štít. Samozřejmě, že zadlužení společnosti s sebou nese dodatečné riziko, nicméně při rozumné úrovni zadlužení lze benefitovat z levnějšího dluhového financování snížením celkových nákladů kapitálu a tím způsobeným růstem hodnoty podniku. Vzhledem k tomu, že finanční struktura BB (jak dlouhodobé, tak krátkodobé zdroje) z porovnávací analýzy vyplynula jako konzervativní, jsou připraveny dva scénáře. V prvním scénáři dojde ke změně ve vlastním kapitálu, který bude nahrazen dluhovým financováním. Ve druhém scénáři dojde i ke změnám v pracovním kapitálu.

V době psaní byla nejnovější výroční zpráva z roku 2019 a firma odmítla spolupracovat a poskytovat informace nad rámec veřejně dostupných. Finanční model tedy obsahuje predikce již od roku 2020.

[#] Článek je zpracován jako jeden z výstupů výzkumného projektu Fakulty financí a účetnictví VŠE, který je realizován v rámci institucionální podpory VŠE IP100040. Podkladem k článku je diplomová práce Ing. Davida Chudomského, vedená Ing. Radanou Šmídovou, Ph.D., obhájená na Katedře financí a oceňování podniku VŠE Praha v červnu 2021.

^{*} Ing. David Chudomský – absolvent Fakulty financí a účetnictví VŠE Praha.

^{**} Ing. Radana Šmídová, Ph.D. – odborný asistent; Katedra financí a oceňování podniku, Fakulta financí a účetnictví, Vysoká škola ekonomická v Praze.

Finanční analýza společnosti

Tab. 1: Agregovaná rozvaha 2016 – 2019

Aktiva		2016	2017	2018	2019
Dlouhodobý nehmotný majetek	tis. Kč	36 730	31 892	29 147	37 266
Dlouhodobý hmotný majetek	tis. Kč	2 048 601	2 549 272	2 729 108	3 174 719
Dlouhodobý finanční majetek	tis. Kč	10 462	10 002	10 059	9 962
Dlouhodobý majetek celkem	tis. Kč	2 095 793	2 591 166	2 768 314	3 221 947
Zásoby	tis. Kč	332 574	299 666	344 683	330 111
Dlouhodobé pohledávky	tis. Kč	-	5 494	-	4 904
Krátkodobé pohledávky z obchodních vztahů	tis. Kč	389 916	391 231	401 728	449 447
Ostatní pohledávky	tis. Kč	17 337	60 939	45 487	36 492
Krátkodobý finanční majetek	tis. Kč	200 000	200 000	599 999	200 002
Peníze	tis. Kč	1 904 850	1 637 297	776 645	1 056 348
Časové rozlišení	tis. Kč	154 795	142 049	138 485	173 517
Oběžná aktiva celkem	tis. Kč	2 999 472	2 736 676	2 307 027	2 250 821
Aktiva celkem	tis. Kč	5 095 265	5 327 842	5 075 341	5 472 768

Pasiva		2016	2017	2018	2019
Základní kapitál	tis. Kč	3 100 000	3 100 000	3 100 000	3 100 000
Kapitálové, rezervní a ostatní fondy celkem	tis. Kč	613 332	622 741	606 411	630 450
Výsledek hospodaření minulých let	tis. Kč	515 786	775 437	520 872	777 398
Výsledek hospodaření běžného období	tis. Kč	264 381	254 927	267 135	278 074
Vlastní kapitál celkem	tis. Kč	4 493 499	4 753 105	4 494 418	4 785 922
Dlouhodobý dluh	tis. Kč	-	-	-	-
Krátkodobý dluh	tis. Kč	-	-	-	-
Dluh celkem	tis. Kč	-	-	-	-
Rezervy	tis. Kč	42 297	33 320	95 584	51 601
Dlouhodobé závazky	tis. Kč	122 321	118 583	105 805	123 779
Krátkodobé neúročené závazky					
Krátkodobé závazky z obchodního vztahu	tis. Kč	275 396	295 565	217 961	243 775
Přijaté zálohy	tis. Kč	28 117	2 750	49	60 337
Ostatní krátkodobé závazky	tis. Kč	133 544	124 518	161 524	207 354
Časové rozlišení	tis. Kč	91	1	-	-
Cizí zdroje celkem	tis. Kč	601 766	574 737	580 923	686 846
Pasiva celkem	tis. Kč	5 095 265	5 327 842	5 075 341	5 472 768

Zdroj: vlastní zpracování

Tab. 2: Agregovaná výsledovka 2016 – 2019

Výsledovka		2016	2017	2018	2019
Celkové tržby	tis. Kč	2 611 891	2 543 244	2 702 491	2 873 807
Náklady na prodané zboží	tis. Kč	(61 043)	(58 712)	(52 174)	(53 656)
Spotřeba materiálů	tis. Kč	(932 789)	(968 533)	(994 703)	(1 014 197)
Spotřeba energie	tis. Kč	(83 876)	(81 203)	(84 662)	(87 742)
Opravy a udržování	tis. Kč	(69 593)	(58 957)	(44 110)	(41 248)
Marketing	tis. Kč	(376 771)	(328 152)	(306 688)	(355 801)
Ostatní nakupované služby	tis. Kč	(210 021)	(230 220)	(261 914)	(271 518)
Změna stavu zásob vlastní činnosti	tis. Kč	(8 663)	18 513	45 525	(9 816)
Osobní náklady	tis. Kč	(313 706)	(336 696)	(382 264)	(426 112)
Odpisy dlouhodobého nehmotného a hmotného majetku	tis. Kč	(236 139)	(187 858)	(255 530)	(307 521)
Ostatní provozní náklady a výnosy	tis. Kč	28 163	9 597	(47 709)	31 811
Celkové provozní náklady	tis. Kč	(2 264 438)	(2 222 221)	(2 384 229)	(2 535 800)
Provozní výsledek EBIT	tis. Kč	347 453	321 023	318 262	338 007
Výnosové úroky	tis. Kč	1 286	764	3 467	19 414
Nákladové úroky	tis. Kč	-	-	-	-
Ostatní finanční výnosy	tis. Kč	7 768	6 252	9 013	7 450
Ostatní finanční náklady	tis. Kč	(12 349)	(14 719)	(2 849)	(662)
Změna stavu rezerv a opravných položek ve finanční oblasti	tis. Kč	(6 895)	1 400	12	(552)
Finanční výsledek hospodaření	tis. Kč	(10 190)	(6 303)	9 643	25 650
Daň ze zisku	tis. Kč	(72 882)	(59 793)	(60 770)	(85 583)
Čistý zisk	tis. Kč	264 381	254 927	267 135	278 074

Zdroj: vlastní zpracování

BB spolu s Plzeňským Prazdrojem, Staropramenem a Heineken ČR patří mezi čtyři největší české pivovary a pro porovnání byla tedy zvolena tato skupina pivovarů. Sledované finanční ukazatele byly získány z výročních zpráv příslušných podniků a sledují roky 2016 – 2019.

Z výše uvedené agregované rozvahy vyplývá, že podíl cizích zdrojů na aktivech je přibližně 13 %, přičemž v minulosti byl i nižší. Ostatní sledované pivovary však dosahují hodnot kolem 60 %. Podíl dluhu na aktivech je u BB ve sledovaném období 0 %, u ostatních pivovarů byl historicky kolem 30 %, ale v posledních letech klesal.

Z analýzy složek pracovního kapitálu byla sledována doba obratu zásob, pohledávek a závazků. Ve všech ukazatelích je BB dlouhodobě nejkonzervativnější. V roce 2019 BB dosahoval doby obratu zásob 42 dní, přitom ostatní pivovary se pohybovaly v intervalu 13-24 dní. U pohledávek není rozdíl tak markantní, ale přesto BB s 57 dny má vyšší dobu obratu než druhý nejpomalejší Staropramen s 48 dny. Plzeňský Prazdroj však dosahuje doby obratu 25 dní. V případě doby obratu závazků BB naopak dosahuje stabilně nejnižších čísel ze sledované skupiny, a to v roce 2019, kdy činí 49 dní. Plzeňský Prazdroj měl dobu obratu dokonce 106 dní, Staropramen 90 dní a Heineken ČR 67 dní. Ukazatel peněžní konverze je u BB v roce 2019 na úrovni 50 dní. Ostatní pivovary se pohybují v záporných číslech, a to

v celém sledovaném období. Plzeňský Prazdroj měl v roce 2019 peněžní konverzi dokonce záporných 58 dní.

Podíl přijatých krátkodobých záloh na tržbách u BB v roce 2019 dosahoval 2 %, přitom ostatní pivovary mají přijaté zálohy za 7 – 8 % tržeb, v minulosti i více. Tento ukazatel však může být ovlivněn strukturou odběratelů a z výroční zprávy není patrné, na co přesně jsou zálohy určeny. Pokud by se ale jednalo o účelově stejné zálohy, nabízí se otázka, proč BB požaduje méně záloh než ostatní pivovary.

Z hlediska ukazatelů likvidity je BB díky vysokým zůstatkům peněžních prostředků a malému objemu závazků zcela mimo hodnoty ostatních pivovarů. Ukazatel okamžité likvidity má sice v období 2016 – 2019 klesající trend, nicméně hodnota 2,5 v roce 2019 je stále výrazně nad druhou nejvyšší hodnotou 0,4, které dosahuje Staropramen. Ostatní pivovary se v celém sledovaném období pohybují v intervalu 0,1 – 0,5.

Při porovnání ziskovosti pivovarů je Plzeňský Prazdroj výrazně nad ostatními z hlediska EBITDA i čisté marže. Ostatní pivovary však dosahují relativně srovnatelné EBITDA marže kolem 20 % (BB je třetí nejlepší). Čistá marže BB se dlouhodobě pohybuje na 10 % a stejně jako Staropramen, tak Heineken ČR dosahuje dlouhodobě spíše nižších hodnot.

Výnosnost vlastního kapitálu BB se dlouhodobě pohybuje kolem 6 %, přičemž slabší je jen málo ziskový Staropramen. V roce 2019 bylo ROE Heineken ČR 34 % a Plzeňského Prazdroje 70 %.

Pro srovnání BB s evropskými pivovary bylo v databázi CapitalIQ analyzováno 18 společností. Z analýzy vyplývá:

- medián podílu dluhu na celkovém kapitálu byl 31 % (BB – 0 %)
- medián ukazatele zadlužení čistý dluh / EBITDA byl 1,5 (BB – teoreticky záporný)
- medián podílu čistého pracovního kapitálu na tržbách byl 0 % (BB – 17 %)
- medián pohotové likvidity byl 0,6 (BB – 3,4)
- medián EBITDA marže v roce 2019 byl 15 % (BB – 23 %)
- medián čisté marže byl 7 % (BB – 10 %)
- medián ROE byl 13 % (BB – 6 %)

Z analýzy českých i evropských pivovarů vyplývá, že BB má velmi konzervativní kapitálovou strukturu, bez dluhového financování a 87 % aktiv kryje vlastní kapitál jako nejdražší zdroj financování. Kromě neexistujícího dluhu je i pracovní kapitál velmi konzervativně řízen. V zásobách a pohledávkách je vázáno hodně peněžních prostředků a na druhou stranu dodavatelům je placeno relativně rychle. K tomu měla firma v roce 2019 přibližně 1,3 mld. Kč v peněžních prostředcích nebo likvidních finančních aktivech, což způsobovalo výrazně odlišné a velmi konzervativní ukazatele likvidity v porovnání s ostatními pivovary.

Přestože podnik dosahuje dobrých ziskových marží v českém i evropském srovnání, ROE je nižší než u ostatních pivovarů, a to právě kvůli množství kapitálu, který je v podniku vázán. V případové studii proto byla namodelována transakce dividendové rekapitalizace, která by umožnila nahradit část vlastního kapitálu dluhem a přebytečné peněžní prostředky

vyplatit na mimořádné dividendě vlastníkovu podniku, který je následně může investovat do jiných projektů, než je BB a potenciálně dosáhnout vyšší výnosnosti.

Při analýze historické výnosnosti podniku byly porovnány náklady vlastního kapitálu (odhadnuté dle modelu CAPM) a ROE. V letech 2017 a 2018 dle zvolených předpokladů nebylo ROE vyšší než odhadnuté náklady kapitálu. Modelovaná transakce by měla zvýšit ROE zejména implementací finanční páky a zároveň snížit náklady kapitálu využitím dluhového financování v rozumné míře.

Model dividendové rekapitalizace

Vzhledem k nulovému zadlužení firmy (je vycházeno z tradiční teorie kapitálové struktury) se usuzuje, že kapitálová struktura nemůže být optimální a nedochází tak ani k maximalizaci hodnoty firmy. Smyslem je tedy simulace transakce dividendové rekapitalizace a ukázat, za jakých předpokladů by mohlo dojít k bezpečné změně finanční struktury.

Na základě finančního modelu je kvantifikován její dopad na finanční pozici společnosti s důrazem na výnosnost vlastního kapitálu. Finanční model vychází z účetních dat ke konci roku 2019 a další období jsou odhadnuta na základě předpokladů, které jsou níže zjednodušeně popsány.

Finanční model generuje finanční plán v letech 2020–2024. Důraz je kladen na finanční strukturu a její dopad na výnosnost vlastního kapitálu. Provozní předpoklady jsou nastaveny konzervativně víceméně na základě historie, aby měla ziskovost minimální dopad na změnu ROE.

Model obsahuje dva scénáře a hlavní změny jsou provedeny v dlouhodobém financování (scénář A i B) a pracovním kapitálu (pouze scénář B). Přebytná hotovost vzniklá z rekapitalizace v roce 2020 je následně vyplacena jako mimořádná dividendou snížením vlastního kapitálu.

Předpoklady modelu

Klíčovým vstupem je předpokládaný výstav podniku. V minulých letech BB provádí investice do zvýšení kapacity pivovaru a plánuje výstav navyšovat. Dle tiskové zprávy z 28. 1. 2020 na webových stránkách firmy vyplývá, že celkový prodaný objem vzrostl o 3 % (o 2 % na domácím trhu) a celkové tržby za pivo o 1 %. Tyto hodnoty poslouží pro odhad výnosů roku 2020 jako roku silně ovlivněného pandemií koronaviru. Kromě roku 2021, kdy je předpokládán 4% růst v důsledku ústupu pandemie, je růst výstavu držen konzervativně na 3 %, což je úroveň, která byla dosažena i v pandemickém roce. Celkový výstav tak v roce 2024 vzroste až na úroveň 1 965 465 hl za rok, což je stále pod produkční kapacitou 2 mil. hl, kterou BB brzy předpokládá dosáhnout rozšiřovacími investicemi, které v posledních letech provádí a neměl by proto být problém s výrobní kapacitou. Růst tržeb za 1 hl piva dlouhodobě zaostává za inflací. Tržba za rok 2020 je dopočtena z tiskové zprávy a další roky jsou navázány na odhad inflace ČNB.

Z hlediska nákladů je materiál nejvýznamnějším nákladovým vstupem a je indexován prognózovanou inflací. Stejně tak u energií a služeb se očekává růst s inflací. Pro odhad


marketingových nákladů je použit jejich podíl na tržbách v roce 2019. Nejsou plánovány dramatické změny v počtech zaměstnanců a růst mzdových nákladů v roce 2020 reflektuje kolektivní smlouvu (3 %), v dalších letech je růst převzat z makroekonomické prognózy MF.

Investice 500 mil. Kč jsou plánovány v letech 2020 – 2022, v následujících letech jsou investice na úrovni 400 mil. Kč. Pro účely modelu byly spojeny položky ostatních nákladů a výnosů a do budoucna se předpokládá, že BB ročně v těchto dvou položkách bude mít tržbu asi 5,5 mil. Kč. Jedná se o průměr posledních 4 let.

Kromě ztrát na tržbách (zejména z ostatních a gastro služeb) model nepředpokládá žádné náklady spojené s koronavirem. Nutno ale podotknout, že pokles tržeb přímo propadá do zisku firmy, neboť alokace nákladů na jednotlivé segmenty není možná a s ukončením či omezením provozu tohoto segmentu by měly být spojeny i nižší náklady, což model nezohledňuje a měl by tedy ukazovat konzervativnější čísla. Na konkrétní odhady dopadu pandemie na BB bohužel není dostatek informací, a proto v roce 2020 složka ostatních nákladů a výnosů obsahuje i 25 mil. Kč (přibližně 37 tis. Kč na 1 zaměstnance) extra nákladů a v dalším roce ještě 10 mil. Kč na různé náklady spojené s pandemií (ochranné pomůcky či nedobytné pohledávky). Zároveň nejsou uvažovány žádné druhy podpor od státu, které by naopak hospodaření mohly vylepšit.

Graf níže ukazuje vývoj historických i predikovaných ukazatelů ziskové marže na úrovni EBIT a EBITDA. Z grafu zároveň vyplývá, že v porovnání s historií model po krizovém pandemickém roce plánuje pouze pozvolný růst ziskovosti, víceméně na historické úrovni. EBITDA marže se v posledních letech modelu pohybuje mírně nad historickými hodnotami zejména kvůli růstu odpisů, které oproti roku 2019 vzrostly v roce 2024 o 76 mil. Kč.

Obr. 1: Historická a prognózaná provozní ziskovost



Zdroj: vlastní zpracování

Z hlediska předpokladů týkajících se rozvahových položek studie pracuje s dříve zmíněnými dvěma scénáři. Scénář A nahrazuje vlastní kapitál dluhem a scénář B ještě k tomu agresivněji řídí pracovní kapitál. Scénář A tedy v pracovním kapitálu pracuje s hodnotami na úrovni historických průměrů a scénář B vychází z předpokladu, že by se BB dostal na úroveň průměru obrátkovosti tří českých pivovarů, se kterými byl srovnáván ve finanční analýze a došlo by tak k agresivnějšímu řízení pracovního kapitálu. Ve scénářích jsou plánovány zásoby, obchodní pohledávky, obchodní závazky a zálohy. Ostatní položky mají stejný vývoj v obou scénářích a u krátkodobého finančního majetku je předpokládáno jeho zpeněžení.

Klíčové pro celou simulovanou transakci jsou předpoklady financování a požadované finanční ukazatele. Model je nastaven tak, že dojde k načerpání dluhu v roce 2020 tak, že zadlužení (čistý dluh / EBITDA) se v roce 2024 dostane na úroveň 1,5 (medián evropských pivovarů), přičemž do té doby je zadlužení vyšší. Požadovaná okamžitá likvidita pro rok 2020, kdy se uskuteční transakce, je nastavena na 0,24 (průměr ostatních 3 českých pivovarů za sledované období). U splátek úvěru je předpoklad jejich přizpůsobení na míru a úvěr je tedy splácen tak, aby DSCR dosahovalo maximálně hodnoty 1,2. Úrokové náklady jsou odhadnuty na základě prognózy PRIBOR 3M a dlouhodobé bankovní marže, a zároveň je předpokládána i jejich plná daňová uznatelnost. Transakční náklady celého procesu jsou odhadnuty jako 2,5 % z načerpané částky dluhového financování a pokrývají potenciální náklady na právní či ekonomické poradenství a případně další náklady na získání nového financování.


Výstupy finančního modelu

Na základě výše zmíněných předpokladů model kvantifikuje výstupy, které jsou představeny v následujícím textu.

Scénář A

Níže uvedený graf znázorňuje faktory, které v roce 2020 ovlivňují výši peněžních prostředků BB. Výchozí hodnotou je stav z konce roku 2019. Následuje generovaný zisk a odpisy roku 2020, prodej finančních investic, načerpání úvěru, investice, malá změna v pracovním kapitálu a výrazný dopad má mimořádná dividenda, která sníží zůstatek peněžních prostředků na modelovanou hodnotu okamžité likvidity. Ve scénáři A tak lze při pouhé změně kapitálové struktury při výše uvedených parametrech načerpat dluh 2 138 mil. Kč a následně z podniku vyplatit téměř 3,2 mld. Kč na mimořádné dividendě.

Obr. 2: Scénář A – Dopad transakce na peněžní zůstatek 2020




Zdroj: vlastní zpracování

Zadlužení samozřejmě vzroste, jak podíl cizích zdrojů, tak dluhu na celkovém kapitálu po transakci výrazně vzroste. V následujících letech se však zadlužení snižuje. Z analýzy české konkurence vyplývá, že v roce 2019 je průměrný podíl cizích zdrojů na aktivech u tří českých pivovarů 60 %. Tuto hodnotu BB v prvních dvou letech sice mírně překročí, ve třetím roce se

dostává na 57 % a v dalších dvou letech klesá až na 46 %. Zároveň krytí dlouhodobých aktiv vlastním kapitálem nebo dlouhodobým dluhem (tzn. dlouhodobým kapitálem pro účely sladení peněžního toku z investice a jejich zdrojů) je vyšší než 1, tzn. dlouhodobým kapitálem je financována i část krátkodobých aktiv, což je konzervativnější přístup finančního řízení.


Obr. 3: Scénář A - vývoj zadlužení



Zdroj: vlastní zpracování

Nejvýznamnějším výstupem finančního modelu je kvantifikace změny finanční struktury na výnosnost pro vlastníka. Následující graf ukazuje vývoj ROE za sledované období včetně jeho rozložení na tři komponenty (čistá zisková marže obrát aktiv, finanční páka) ve formě indexů, pro které je základnou rok 2016. Z grafu vyplývá, že výnosnost vlastního kapitálu je prognózována více než dvojnásobná oproti historickým úrovním (kromě roku 2020 kde na ziskovost silně dopadne pandemie koronaviru a jednorázové transakční náklady). Za zvýšením ROE však nestojí vyšší ziskovost (její hodnoty jsou dokonce v letech 2020 – 2023 nižší než v roce 2019). BB díky výplatě peněžních prostředků snížil svá aktiva a zvýšil tak jejich obrát, čímž zefektivnil svůj chod. Nejdůležitějším faktorem je však výrazný růst finanční páky. V prvních letech BB díky novému dluhu využívá finanční páky, která je více než dvojnásobná oproti historickým úrovním. S postupným růstem vlastního kapitálu a splácením dluhu však síla finanční páky ke konci modelu klesá a s tím dochází k mírnému poklesu ROE, přesto ale ROE výrazně převyšuje historické hodnoty.

Obr. 4: Scénář A – ROE




Zdroj: vlastní zpracování

Scénář B

Následující graf znázorňuje dopad transakce na výši peněžních prostředků BB v roce 2020 ve scénáři B. V tomto scénáři dochází ke změně kapitálové struktury a zároveň ke změnám v pracovním kapitálu. Dle výstupu modelu lze načerpat dluh 2 378 mil. Kč a následně z podniku vyplátit 4,0 mld. Kč na mimořádné dividendě. Nejvýznamnější rozdíl oproti scénáři A je tvořen pracovním kapitálem, ze kterého je vyvázáno o 673 mil. Kč více než ve scénáři A, což je způsobeno odlišnými předpoklady při plánování položek pracovního kapitálu (Scénář A je víceméně historický průměr BB a Scénář B je historický průměr zmíněných tří českých pivovarů, se kterými byl BB porovnáván).

Obr. 5: Scénář B – Dopad transakce na peněžní zůstatek 2020




Zdroj: vlastní zpracování

Zadlužení ve scénáři B dosahuje vyšších úrovní kvůli vyššímu dluhu, nicméně v roce 2024 dojde k poklesu ukazatele zadlužení čistý dluh/EBITDA na 1,5 jako ve scénáři A. Podíly

cizích zdrojů a dluhu postupně dosáhnou hodnot odpovídajících hodnotám, které vyplývají z analýzy českých pivovarů (podíl cizích zdrojů na aktivech – 60 %; podíl dluhu na aktivech – 30 %). Zároveň krytí dlouhodobých aktiv vlastním kapitálem nebo dluhem dosahuje úrovně 1 (kromě roku 2020).


Obr. 6: Scénář B – Vývoj zadlužení



Zdroj: vlastní zpracování

Dle očekávání scénář B dosahuje ještě vyšších hodnot ROE a téměř čtyřnásobku historických hodnot. Vyšší ROE opět není způsobeno vyšší ziskovostí (pozn. provozní předpoklady jsou stejné jako pro scénář A). Až v roce 2024 se ziskovost dostane k úrovni roku 2019, jinak se pohybuje dokonce níže. BB ale díky výplatě peněžních prostředků snížil svá aktiva a zvýšil tak jejich obrát, čímž zefektivnil svůj chod, podobně jako ve scénáři A. Růst obrátu aktiv z 1,02 na 1,31 v roce 2020 (a až na 1,43 v roce 2024) má pozitivní vliv na ROE. Nejdůležitějším faktorem je však změna finanční páky, která je velmi výrazná. V roce 2020 BB díky novému dluhu využívá finanční páky, která je více než čtyřnásobná oproti historickým úrovním. S postupným růstem vlastního kapitálu a splácením dluhu však síla finanční páky klesá na přibližně dvojnásobek roku 2016. S poklesem finanční páky dochází i k poklesu výnosnosti vlastního kapitálu. Z více než 21 % v roce 2022 dochází v roce 2024 k poklesu na necelých 18 % právě z důvodu klesající finanční páky. Nutno podotknout, že v roce 2024 BB dosahuje ukazatel zadlužení čistý dluh/EBITDA hodnoty 1,5 a pohybuje se tedy na modelovaném stavu, který je považován za tržní zadlužení (dle analýzy evropských pivovarů).

Obr. 7: Scénář B – ROE



Zdroj: vlastní zpracování

Zohlednění zvýšeného finančního rizika

S finanční pákou je bezpochyby spojeno finanční riziko. Dle tradiční teorie nákladů kapitálu však již samotný posun k optimálnímu zadlužení (převzatého z evropského trhu na 1,5 čistý dluh/EBITDA) z nulového zadlužení představoval finanční optimalizaci, která zvyšuje hodnotu podniku.

Ve studii byla snaha zohlednit růst finančního rizika ještě kalkulací poměru ROE a pravděpodobnosti selhání podniku (aproximace finančního rizika podniku). Ke kalkulaci tohoto finančního rizika byla použita metodika Moody's (konkrétně metodologie relevantní pro firmy pohybující se v odvětví alkoholických nápojů z 25. 2. 2020 – „Alcoholic Beverages Methodology“) pro kreditní skóring. Na základě metodiky byl odhadnut kreditní rating BB ve scénáři bez transakce a ve scénářích A a B. Nutno podotknout, že hodnocení se lišilo pouze u faktorů týkajících se finančních ukazatelů a finanční politiky podniku. Výsledný rating pro BB bez transakce vyšel Baa1 a pro scénář A i B Baa3. Na základě výzkumu Moody's byly získány pravděpodobnosti selhání podniků v horizontu deseti let pro jednotlivé kreditní ratingy a tato pravděpodobnost je považována za finanční riziko pro příslušný rating. Prognózané ROE v roce 2024 bylo následně vyděleno příslušnou pravděpodobností selhání pro každý scénář. Tento poměr říká, kolik jednotek výnosu získá BB za jednotku podstoupeného rizika a čím vyšších hodnot dosahuje, tím lépe. Ve scénáři bez transakce vychází tento poměr 2,75 a ve scénáři A pouze o 1 setinu lépe (metodologie nezohledňuje drobné rozdíly – kreditní skóre se ve scénáři A pohybuje těsně na hranici Baa2 a Baa3, ale pravděpodobnost selhání je konzervativně uvažována zcela pro Baa3). Scénář B ovšem vychází výrazně lépe a kalkulovaný poměr ROE a finančního rizika říká, že BB v roce 2024 generuje 3,9 ROE na jednotku rizika po transakci ovlivňující kapitálovou strukturu a pracovní kapitál.

Závěr

Přestože není vlastní kapitál spojen s nákladovými úroky, požaduje racionální investor odměnu za poskytnutí kapitálu. Dle teorie podnikových financí je dokonce dražším zdrojem financování než kapitál cizí. Jeho cena je určena požadovanou výnosností vlastníka. Racionální vlastník očekává, že jeho investice (kapitál vázaný ve firmě) mu přinese výnos. Kapitálová struktura BB je pozoruhodná zejména kvůli nulovému zadlužení, velmi vysoké likviditě a velkému množství peněžních prostředků. Nabízí se tak otázka, zda by nebylo efektivnější, kdyby si vlastník prostředky vyplatil a investoval je jinde a s vyšším výnosem. Jeho podnik by mohl financovat jiní poskytovatelé kapitálu, kteří by se spokojili s nižším výnosem. Při výši vlastního kapitálu, kterou vykazuje BB v posledních letech, je jeho výnosnost hraniční s jeho náklady (za předpokladu, že náklady vlastního kapitálu národního podniku lze určovat modelem CAPM).

Předpokládá se, že je v zájmu vlastníka, aby BB tvořil hodnotu a fungoval ekonomicky efektivně. Podle zákona č. 77/1997 Sb. § 12a „ředitel je povinen počínat si s péčí řádného hospodáře a zajistit, aby plnění významných strategických, hospodářských, společenských, bezpečnostních a dalších zájmů státu bylo realizováno účelně, hospodárně a efektivně“. Stejně tak zakladatel (Ministerstvo zemědělství) kontroluje „zda potřeby státu, které podnik svou podnikatelskou činností zabezpečuje, jsou zajišťovány účelně a hospodárně“. BB má dobrou pozici v tom, že je dostatečně ziskový, nicméně výnosnost vlastního kapitálu je snižována jeho výší. V takovém případě lze však ROE navýšit relativně jednoduše – využitím finanční transakce.

Tato případová studie představuje BB ve dvou alternativních scénářích kapitálové struktury. Změny kapitálové struktury je dosaženo transakcí dividendové rekapitalizace, kdy je vyplacena vysoká mimořádná dividenda (více než 3 mld. Kč), která je částečně financována dluhovým financováním. Předpokládá se, že Ministerstvo zemědělství (jako zakladatel BB) bude mít projekty s vyšší výnosností vlastního kapitálu, než bylo dosahováno v BB, a dojde tak k efektivnější alokaci kapitálu. Výše mimořádné dividendy se může zdát relativně vysoká, což je způsobeno strukturováním transakce, která vlastně z firmy odebere prostředky za minulé, ale i budoucí roky, neboť je financována dluhem, který je následně splácen na úkor výplaty dividend. Potenciální budoucí dividendy jsou tedy vyplaceny dříve (což způsobuje vyšší zadlužení v prvních letech predikce) a v příštích letech je umořován dluh a nezbývají peněžní prostředky na výplatu dividend. Zároveň by se v prvních letech firma mohla zdát předlužená, nicméně to je opět příčinou toho, že se předpokládá provést celou transakci najednou, postupně však zadlužení klesá na modelovanou hodnotu, která vychází z analýzy evropských pivovarů. Jedná se pouze o jeden konkrétní příklad strukturování transakce a jistě by šlo rekapitalizaci provést postupně, aby nedocházelo k tak razantnímu zadlužení v prvních letech.

Pravděpodobně již minulé nebo stávající investice firma mohla financovat i dluhovým financováním a v kapitálové struktuře by se tak objevily dodatečné cizí zdroje, které by způsobily vyšší finanční páku a úrokový daňový štít a přebytečné peněžní prostředky mohly být vypláceny vlastníkovi. To, že je některý zdroj kapitálu aktuálně k dispozici (myšleno peněžní prostředky na účtech BB) neznamena, že je efektivní ho využít (z pohledu vlastníka), přestože to může být i pro management jednodušším řešením financování. Důvodů, proč by BB byl schopný nést dluhové financování, je několik. BB je stabilní, ziskový a na české prostředí i relativně velký podnik, který se pohybuje na stabilním trhu. Zároveň aktiva BB tvoří zejména dlouhodobá aktiva, která by mohla sloužit jako zástava a dále snížit riziko pro případného věřitele.

Dle sestaveného finančního modelu a zvolených parametrů lze usoudit, že i při razantní jednorázové změně ve finanční struktuře BB by jeho finanční stabilita neměla být ohrožena a firma by zůstala solventní a likvidní. Změna by způsobila očekávaný efekt finanční páky a výnosnost vlastního kapitálu by výrazně vzrostla. Navíc z analýzy dopadu na odhad kreditního ratingu podle metodologie Moody's vyplývá, že výnos roste rychleji než riziko. Předpokládá se, že racionální riziko-averzní investor bude vyhledávat investice s lepším poměrem rizika k výnosu, a proto by z popsané transakce benefitoval. Nelze ovšem upřít, že celkové riziko společnosti s navýšením finanční páky samozřejmě roste.

Na základě této případové studie se usuzuje, že úpravou finanční struktury BB by došlo k efektivnější kapitálové struktuře a realizaci vyššího výnosu pro vlastníka, kterým jsou ve výsledku všichni občané České republiky. Možnosti jsou různé, tato studie se pouze snažila ukázat, že prostor pro využití dluhového financování zde je a jeho výhody by převážily nevýhody.

Dodatek

Výroční zpráva za rok 2020 byla zveřejněna po dokončení studie a vyplývá z ní, že rok 2020 byl výrazně úspěšnější, než bylo předpokládáno v modelu. Finanční model počítal s čistým ziskem kolem 160 mil. Kč (po očištění o úrokové a transakční náklady), ve skutečnosti ale čistý zisk dosáhl 305 mil. Kč. BB si přes restriktce a lockdowny (s dopadem zejména na on-trade segment) zachoval čistou ziskovou marži přes 10 %. Došlo ke zvýšení peněžních prostředků a peněžních ekvivalentů o 125 mil. Kč na 1 301 mil. Kč a nedošlo k výplatě dividendy ani získání dluhového financování.

Finanční model měl být konzervativně nastaven, aby se ukázalo, zdali transakce funguje i při opatrném nastavení. Vzhledem k tomu, že rok 2020 dopadl lépe, než model prognózoval (vyšší marže a další růst peněžních prostředků a peněžních ekvivalentů), byla by ve skutečnosti zvažovaná transakce pro BB, respektive jeho vlastníka, ještě výhodnější.

Literatura:

- [1] Beer Global Market Report 2021 Including Market Size, Share & Growth Analysis, Global Beer Consumption Statistics. GlobeNewswire [online]. Los Angeles: GlobeNewswire, 2021 [cit. 2021-4-5]. Dostupné z: <https://www.globenewswire.com/newsrelease/2021/03/24/2198697/0/en/Beer-Global-Market-Report-2021-Including-MarketSize-Share-Growth-Analysis-Global-Beer-Consumption-Statistics.html>.
- [2] Beer. Statista [online]. Hamburg: Statista, 2021 [cit. 2021-4-5]. Dostupné z: <https://www.statista.com/outlook/cmo/alcoholic-drinks/beer/worldwide>.
- [3] Budějovický Budvar [online]. České Budějovice: Budějovický Budvar, 2021 [cit. 2021-4-5]. Dostupné z: <https://www.budejovickybudvar.cz/>
- [4] Capital IQ [online]. New York: S&P Global Market Intelligence, 2021 [cit. 2021-3-9]. Dostupné z: <https://www.spglobal.com/marketintelligence/en/solutions/sp-capital-iqplatform>.

- [5] Damodaran online [online]. New York: Aswath Damodaran, 2021 [cit. 2021-3-20]. Dostupné z: <http://pages.stern.nyu.edu/~adamodar/>.
- [6] Chudomský, D. (2021): Kvantifikace výnosnosti vlastního kapitálu Budějovického Budvaru při alternativní finanční struktuře. Diplomová práce, vedoucí Šmídová R. Vysoká škola ekonomická v Praze, Katedra financí a oceňování podniku
- [7] LEVERAGED BUYOUT ANALYSIS. Street of Walls [online]. New York: Street of Walls, 2021 [cit. 2021-3-29]. Dostupné z: <http://www.streetofwalls.com/finance-trainingcourses/investment-banking-technical-training/leveraged-buyout-analysis/>
- [8] LJUNGGREN, PETTER. Dividend Recapitalization. Financial Edge [online]. New York: Financial Edge, 2020 [cit. 2021-3-29]. Dostupné z: <https://www.fe.training/freeresources/accounting/dividend-recapitalization/>
- [9] Makroekonomická predikce - leden 2021. Ministerstvo financí České republiky [online]. Praha: Ministerstvo financí České republiky, 2021 [cit. 2021-3-29]. Dostupné z: <https://www.mfcr.cz/cs/verejnys Sektor/makroekonomika/makroekonomickapredikce/2021/makroekonomicka-predikce-leden-2021-40599>
- [10] MAŘÍK, Miloš. Metody oceňování podniku: proces ocenění, základní metody a postupy. Čtvrté upravené a rozšířené vydání. Praha: Ekopress, 2018. ISBN 978-80-87865-38-5.
- [11] Private sector debt: loans, by sectors, consolidated - % of GDP. Eurostat [online]. Luxembourg City: Eurostat, 2021 [cit. 2021-3-4]. Dostupné z: <https://ec.europa.eu/eurostat/databrowser/view/tipspd25/default/table?lang=en>.
- [12] Total credit to non-financial corporations (core debt). Bank for international settlements [online]. Basilej: BIS, 2021 [cit. 2021-3-9]. Dostupné z: <https://stats.bis.org/statx/srs/table/f4.1>
- [13] Veřejný rejstřík podle subjektů: Výroční zprávy Budějovického Budvaru a ostatních popisovaných podniků [online]. Praha: Justice.cz, 2021 [cit. 2021-3-4]. Dostupné z: <https://or.justice.cz>

Kvantifikace výnosnosti vlastního kapitálu Budějovického Budvaru při alternativní finanční struktuře – případová studie

David Chudomský - Radana Šmídová

ABSTRAKT

Tento článek se zabývá finanční strukturou podniku a jejím vlivem na výnosnost pro vlastníka. V rámci případové studie je analyzován významný český pivovar Budějovický Budvar s konzervativní finanční strukturou. Hlavním cílem je analýza výnosnosti vlastního kapitálu při alternativní finanční struktuře podniku při zohlednění vyššího finančního rizika, které způsobila zvýšená finanční páka.

Klíčová slova: Rentabilita vlastního kapitálu; Kapitálová struktura; Dividendová rekapitalizace.

Quantification of return on equity of Budweiser Budvar with alternative financial structure - case study

ABSTRACT

This article focuses on financial structure and its impact on return on equity. In the case study an important Czech brewery Budweiser Budvar is analysed. The brewery is currently conservatively financially managed, thus the aim of the article is an analysis of change in return on equity with alternative capital structures while taking extra risk arising from higher leverage into account.

Key words: Return on Equity; Capital structure; Dividend recapitalization.

JEL klasifikace: G32

Může být strojové učení užitečné ve financích podniku a jeho ocenění?

Přehled současného výzkumu[#]

*Veronika Staňková**

Úvod

S napětím očekávám, jak se promění obor financí podniku a jeho oceňování v důsledku nových technologií. Příchod počítačů a internetu v minulosti již zásadní změnu způsobil. Bude strojové učení další krok? Může být strojové učení užitečné ve financích podniku a jeho ocenění?

Tento článek si klade za cíl udělat přehled o současném výzkumu v oblasti aplikací strojového učení ve financích podniku a jeho oceňování. V současné době se publikuje tak velké množství vědeckých článků v oblasti aplikace strojového učení, že je obtížné se v nich zorientovat. Tím spíše pro většinu ekonomů, kteří nemají znalosti o strojovém učení. Záměrem tohoto článku je na základě rešerše současné literatury poskytnout základní přehled o tom, co strojové učení je a jaký je současný stav poznání v oblasti financí podniku a jeho oceňování. Tento článek by měl pomoci zorientovat se v perspektivách strojového učení těm, kteří se jím doposud nezabývali, ale chtěli by si udržet přehled o moderních trendech.

Struktura dalšího textu je následující: Nejprve popíši metodologii a zdroj dat. Následně zodpovím následující výzkumné otázky:

- Význam strojového učení: Co to strojové učení vlastně je a jaké jsou jeho výhody a nevýhody oproti běžným (statistickým) predikčním modelům?
- Stručný přehled modelů strojového učení: Jaké modely strojového učení existují a který z nich je „nejlepší“?
- Oblasti využití strojového učení ve financích: V jakých podoblastech financí podniku se v současnosti strojové učení aplikuje?
- Shrnutí: Může být strojové učení ve financích podniku a oceňování užitečné?

Metodologie

Vzhledem k rostoucímu zájmu o strojové učení (dále také ML, z angl. machine learning) vzniklo velké množství primárních článků (tj. článků, které testují konkrétní ML model na reálných datech). Za poslední tři dekády vzniklo v rejstříku Web of Science více než několik tisíc relevantních studií (jen kombinace „neural network“ a „finance“ má přes pět tisíc

[#] Článek je zpracován jako jeden z výstupů výzkumného projektu IG104020, který je realizován na Fakultě financí a účetnictví VŠE Praha.

^{*} Ing. Veronika Staňková, doktorand, Katedra financí a oceňování podniku, Fakulta financí a účetnictví, Vysoká škola ekonomická v Praze.

výskytů na Web of Science) a dle zjištění Warin a Stojkov, 2021, str. 8, kteří zmapovali frekvenci výskytu ML klíčových slov na časové ose, je zřejmé, že každým rokem jejich počet exponenciálně roste.

Vedle primárních článků lze nalézt přehledové články (tzv. metastudie), které se vyznačují tím, že zpracovávají informace z několika primárních článků naráz. Několik takových existuje i pro oblast aplikace strojového učení ve financích podniku a jeho oceňování, ale na základě mých zjištění nejsou jednotlivé metastudie reprezentativním přehledem, neboť žádný nepokrývají zkoumanou oblast komplexně (vzhledem k počtu primárních článků možná ani není možné obsáhnout). Z tohoto důvodu je nepovažuji za ucelený přehled vhodný pro začátečníka. Abych doplnila chybějící agregovaný pohled, soustředila jsem se na zpracování přehledu publikovaných metastudií (čili „metastudie podkladových metastudií“) s cílem v maximální míře pokrýt existující literaturu ke zvolenému tématu.

Data

Vzorek metastudií jsem identifikovala kombinací automatického a ručního zpracování pro zajištění optimálního výsledku na základě těchto kritérií:

- kombinace anglických klíčových slov v názvu článku, které dle mého názoru nejlépe popisují přehledový článek v oblasti strojového učení ve financích¹;
- článek byl publikován v posledních třech letech, abych zajistila, že se budu zabývat pouze nejaktuálnějšími výzkumy. Metastudie mají navíc ze své podstaty oproti nejnovějším primárním výzkumům vždy zpoždění;
- vyloučení článků evidentně nesouvisejících s tématem aplikace strojového učení ve financích podniku a jeho ocenění na základě ručního vyhodnocení názvu článku;
- zařazení v databázi Scopus (nezohledňovala jsem počet citací) a
- dostupnost článků v některé z databází EBSCO, ProQuest, JSTOR a Google Scholar.

Celkem bylo vybráno 14 metastudií. Zkoumané metastudie jsou prezentovány v Tabulce 1 na další straně, včetně informace o počtu primárních článků, které byly v dané metastudii analyzovány a z jakého období tyto primární články pocházejí.

¹ Klíčová slova tvořila tři množiny, z nichž musel být nalezen průnik, tj. alespoň jedno slovo z každé skupiny. První skupina popisuje požadovaný formát metastudie (tj. jedno ze slov "review" nebo "research" nebo "survey" nebo "literature" nebo "progress" nebo "analysis" nebo "note"), druhá skupina vyjadřuje souvislost s ML ("machine learning" nebo "deep learning" nebo "neural" nebo "clustering" nebo "random forest" nebo "artificial intelligence" nebo "prediction" nebo "tree") a třetí skupina definuje oblast financí (slova "finance" nebo "equity" nebo "accounting" nebo "stock" nebo "financial" nebo "company" nebo "business").

Tab. 1: Přehled zkoumaných metastudií

Rok vydání	Článek	Počet primárních článků	Analyzované období
2019	[4]	130	2005-2018
2019	[12]	n/a	2001-2018(*)
2019	[15]		2004-2018(*)
2019	[2]	34	1999-2019
2020	[6]	40	2014-2018
2020	[11]	n/a	1998-2018
2020	[8]	33	2017-2020
2020	[17]	n/a	2005-2019 (*)
2020	[14]	140	2005-2019
2021	[7]	124	2017-2019
2021	[1]	27	1994-2019
2021	[16]	50	1990-2019
2021	[3]	58	1995-2019
2021	[18]	5053	1990-2021

Zdroj: vlastní zpracování

Význam strojového učení

O strojovém učení se říká, že se dokáže z poskytnutých vstupních dat sám „učit“. Princip „učení se“ ML modelu, zjednodušeně řečeno, spočívá v tom, že proces tvorby predikčního modelu (model fitting) probíhá uvnitř „automaticky“ analýzou poskytnutých dat. ML model se z poskytnutých dat sám pokouší najít takovou matematickou funkci (čili takové nastavení vnitřních parametrů), která bude z vysvětlujících proměnných predikovat optimální výsledek (např. vysvětlovanou proměnnou). Správné nastavení vnitřních parametrů se hledá automaticky, v iteracích a pomocí integrovaného optimalizačního mechanismu. Kromě vnitřních parametrů je ML model také definován vybranými hyperparametry (v angličtině také tuning parameter), tj. parametry zadanými zvnějšku, autorem modelu s cílem dál vylepšit vytvořený model. Všechny možné kombinace vnitřních parametrů (vytvářející aproximační funkci) se nazývají prostor hypotéz (hypothesis space). Různé ML algoritmy mají odlišné prostory hypotéz, a proto se hodí pro řešení různých otázek.

ML tvoří své predikce pouze na základě poskytnutých dat. Žádný ML model schopen předpovědět něco, co v poskytnutých datech není zachyceno – v tomto je stejný jako běžné statistické modely.

Princip metody strojového učení se popisuje v odborné literatuře od 50. let minulého století (Ghoddusi a kol., 2019, str. 1), ale teprve během minulé dekády se díky rostoucí výpočetní kapacitě (viz Moorův zákon²) a rostoucímu množství a dostupnosti elektronických dat naplno rozvinul potenciál ML.

Modely strojového učení se rozlišují na *učení s učitelem* (supervised) a *učení bez učitele* (unsupervised). Pro učení s učitelem jsou vstupem pro model spárovaná pozorování vysvětlující proměnné (v terminologii ML se nazývají také vstupní atributy, angl. input

² Moorův zákon je pojmenovaný po spoluzakladateli společnosti Intel, který v roce 1965 předpověděl, že se bude počet transistorů umístěných na integrovaný obvod každý rok zdvojnásobovat (později autorem upraveno na frekvenci každé dva roky). Počet zapojených transistorů přímo ovlivňuje výpočetní výkon.

variables nebo features) a vysvětlované proměnné (v ML se nazývá také cílový atribut). Učení bez učitele má k dispozici pouze vysvětlující proměnnou (bez vysvětlované). Podle varianty modelu se mění i cíl predikce:

- Algoritmy učení s učitelem jsou natrénované na vstupních datech, aby predikovaly vysvětlovanou proměnnou pro budoucí pozorování vysvětlujícími proměnnými.
 - Pokud je vysvětlující proměnná spojitá, jedná se o *regresní úlohu* (např. tržní cena), nebo
 - pokud je vysvětlující proměnná kategorická, jedná se o *klasifikační úlohu* (např. určit trend, zda cena bude růst, nebo klesat).
- Naopak algoritmy učení bez učitele mají za cíl zjednodušit (snížit dimenzionalitu) vstupních dat tím, že identifikují spolu související skupiny (clusters) ve *shlukovacích úlohách* anebo jiné důležité vztahy v datech (patterns and correlations).
- Část literatury uvádí jako samostatnou kategorii také tzv. *učení posilováním* (RL, z angl. reinforcement learning), ve kterém pro jednotlivá pozorování není k dispozici údaj o vysvětlované proměnné, ale je poskytnuta zpětná vazba (pozitivní, nebo negativní) v reakci na rozhodnutí. (Mueller a Massaron, 2016, str. 169) Využití RL se nachází především v (hardwarové) robotice. Ve financích podniku rozšířené RL není.

Specifickou kategorií jsou algoritmy na *zpracování přirozeného jazyka* (NLP, z angl. natural language processing). NLP funguje skrz text-mining např. finančních zpráv z Reuters, Bloomberg, textů z výročních zpráv, příspěvků ze sociálních sítí a jiných korpusů textu. NLP algoritmus umí odhadnout např. převládající sentiment na trhu. Následně pak informace o převládajícím sentimentu může být integrována jako vysvětlující proměnná do komplexních modelů. Konkrétně i v oblasti akciového trhu se totiž ukazuje, že určitý sentiment v krátkém horizontu může vysvětlit odchylky ceny pozorované na trzích (Vachhani a kol., 2019, str. 9).

Přednosti strojového učení

Analyzovaná literatura se víceméně shoduje, že ML modely většinou překonávají predikční schopnost běžných statistických modelů (např. Sezer a kol., 2019, str. 1 a Singh a kol., 2021, str. 6). Analyzované články popisují především tyto benefity ML:

- Výborné výsledky predikční přesnosti ML modelů. Vysoká schopnost predikce je dána vysokou flexibilitou ML modelů, která umožňuje zpracovat komplexní nelineární vysokodimenziální vztahy uvnitř dat. (Ghoddusi a kol., 2019, str. 11, 27)
- Možnost zpracování heterogenních dat ve velkých objemech, které mohou být ve strukturované (např. tabulky s čísly), ale i v nestrukturované podobě (např. obrázky, text). (Ghoddusi a kol., 2019, str. 28)
- Menší citlivost některých ML modelů na kvalitu vstupních dat (chybějící pozorování, kolinearita pod.) ve srovnání s tradičními statistickými modely, takže není nutné manuálně upravovat hrubá data (očisťovat o sezónnost, stacionarizace časové řady, hledat strukturální změny, řešit heteroskedasticitu apod.). (Ghoddusi a kol., 2019, str. 28)

- Již naučené ML modely lze v některých případech použít pro jiný úkol (transformovat) a generovat „úspory z rozsahu“. (Ghoddusi a kol., 2019, str. 29)

Limitace strojového učení

Na druhou stranu se v literatuře objevují i upozornění na limitace strojového učení. Patří mezi ně především následující:

- Nutnost velkých dat je základní podmínkou aplikace strojového učení, která může limitovat využití v mnoha oblastech, např. v makroekonomii, kde často bývá jen omezený počet pozorování. (Ghoddusi a kol., 2019, str. 31)
- Existuje riziko přeučení (overfitting), které spočívá v tom, že se model naučí i z šumu (o ničem nevypovídající náhodné složce) v poskytnutých datech. To se projeví tím, že predikce nových pozorování, se kterými se model ještě nesetkal, již nemá dostatečnou přesnost. V důsledku přeučení není model schopen generalizace pro nová data. V podstatě každý (statistický) predikční model trpí rizikem přeučení. (Ghoddusi a kol., 2019, str. 29) Nicméně u ML je toto riziko o to větší, že je velmi flexibilní (model se dokáže naučit i komplikované nelineární vztahy v datech). Z hlavní výhody ML se tedy stává i jeho slabina. Proto podle mého názoru neplatí, že čím komplikovanější ML model (typicky neuronové sítě), tím je zaručena jeho větší úspěšnost. To platí obzvláště v oblasti financí podniku, kde obvykle není zajištěn dostatek kvalitních dat pro bezproblémové učení velmi složitých modelů

V praxi se riziko přeučení snižuje tím, že se dataset rozdělí na (i) trénovací data, (ii) validační data a (iii) testovací data. V situaci dostatku zdrojových dat je typický poměr rozdělení dat 50 %, 25 % a 25 % dle Hastie a kol. 2001 (str. 196). Doporučený postup je (tamtéž) takový, že:

- (i) ML algoritmus se nejprve učí na trénovacích datech (tvorba modelu optimalizací vnitřních parametrů modelu),
- (ii) Validační data se použijí pro nezávislý odhad predikční chyby daného modelu (evaluace) při výběru tzv. hyperparametrů modelu (parametry modelu, které jsou zadány autorem manuálně) a
- (iii) finální vyhodnocení vybraného modelu je provedeno na základě modelem do té doby neviděných testovacích datech.

Protože komplexnost modelu závisí na kvalitě dat, očištěním vstupních dat se dá také snížit riziko přeučení. (Huang a kol., 2020, str. 18).

- Netransparentnost (black box nature) je další z výtek, která je strojovému učení veřejností vytýkána. Nevýhoda spočívá v tom, že není zřejmé, jakým způsobem vyhodnotil algoritmus efekt různých proměnných a jak k prezentovanému výsledku došel (ve srovnání s interpretovatelností např. regresních koeficientů v lineárním regresním modelu). Tady bych ale chtěla upozornit na to, že to neplatí plošně pro všechny ML modely stejně, neboť některé ML modely jsou méně transparentní než jiné (o tomto detailněji při popisu jednotlivých modelů).

Ghoddusi a kol., 2019, str. 31 k tomuto poznamenávají, že ve vyhodnocení, jak významná nevýhoda je netransparentnost ML modelu, závisí také na tom, pro jaký účel se predikce (výstup) ML modelu používají, resp. jestli je kladen důraz na *interpretovatelnost* výsledku nebo na *výsledek* predikce. Typicky v oblastech jako je trading nebo korporátní plánování je důležitý spíše konkrétní výsledek, zatímco typicky pro vědecký výzkum určitého fenoménu je spíše důležité pochopení, jak tento fenomén vzniká (interpretovatelnost).

Strojové učení se typicky nezabývá statistickým testováním významnosti vysvětlujících proměnných, ale spíše ověřuje přesnost modelu porovnáním predikce pro testovací data se skutečností (Ghoddusi a kol., 2019, str. 32).

Stručný přehled modelů strojového učení

Metoda podpůrných vektorů (SVM, z angl. support vector machine)

SVM technika se používá především pro klasifikační úlohy. Spočívá v tom, že namapuje data pomocí jádrové transformace (kernel transformation) do vícedimenziálního prostoru, který pak lineárně separuje. Separace probíhá tak, že v prostoru maximalizuje odstup (maximal margin) mezi skupinami čili seskupuje pozorování tak, aby identifikované skupiny byly navzájem co nejvíce odlišné.

Výhody:

- Výhoda spočívá SVM v tom, že na jedné straně dokáže vystihnout nelineární vztahy mezi daty (i časových řad), ale nestává se tak komplexní jako neuronové sítě, takže netrpí tolik na riziko přeučení se. (Ghoddusi a kol., 2019, str.24)
- SVM obecně vykazuje vysokou přesnost predikce. (tamtéž)
- SVM je schopna tolerovat proměnné, které jsou pro predikci nerelevantní (redundantní). (tamtéž)

Nevýhody:

- Algoritmus SVM je těžko vysvětlitelný (tamtéž), takže následná interpretace je obtížná.
- SVM model se špatně škáluje, např. pokud model natrénovaný na 10 tis. pozorování funguje dobře, neznamená to, že bude také fungovat na datasetu obsahujícím 100 tis. pozorování (Mueller a Guido, 2016, str. 106)

Rozhodovací stromy (Decision trees)

Rozhodovací stromy jsou hierarchický nelineární systém založený na rekurzivním binárním dělení. Každý uzel (node) se dělí na dvě větve (branch), poslední řada uzlů s odpovědí se nazývá list (leaf nebo answer node). Dělení nodu probíhá na základě vhodného atributu a vhodné hraniční hodnoty atributu tak, aby rozdělením došlo k co nejvyššímu zlepšení statistického ukazatele neuspořádanosti systému (impurity measure, např. gini index,

entropie, informační zisk), plní úlohu optimalizačního mechanismu (ztrátové funkce). Statistický ukazatel neuspořádanosti systému zajišťuje, aby byl datový prostor rozdělen na dvě skupiny, které budou co nejvíc homogenní. Nejvyšší přesnosti a efektivity pro testovací data (prevence přeučení) se dělá na základě prořezávání (pruning) stromu od listů ke kořenu, při kterém se rozhodovací strom zjednodušuje tím, že se odstraňují dělení (uzle), které nemají dostatečnou predikční schopnost.

Komplexnější varianta rozhodovacích stromů jsou náhodné lesy (random forests), ve kterém se spojí několik rozhodovacích stromů, každý je vytvořený jako náhodná podmnožina původních dat.

Výhody:

- Rozhodovací stromy jsou koncepčně jednoduché (Hastie, 2001, str. 266) a lze je jednoduše graficky znázornit a interpretovat (neplatí už tolik pro náhodné lesy) (Hastie, 2001, str. 267).
- Algoritmus nevyžaduje předchozí přípravu dat, obzvlášť rozhodovací stromy jsou velmi robustní vůči kvalitě vstupních dat. (Mueller a Guido, 2016, str. 85)

Nevýhody:

- Rozhodovací stromy jsou citlivé na to, že i malá změna v datech vede k velké variabilitě predikčních výstupů. Tato nestabilita souvisí s hierarchickou strukturou, která je pro rozhodovací stromy charakteristická. (Hastie, 2001, str. 275).
- Ve výzkumech jsem se častěji setkala s náhodnými lesy než s jednoduchými rozhodovacími stromy, což zřejmě souvisí s tím, že náhodné lesy a další složitější modely založené na rozhodovacích stromech mají lepší schopnost generalizace (Mueller a Guido, 2016, str. 85).

Neuronové sítě

Hluboké učení (DL, z angl. deep learning) je podoblast ML, která využívá ke svému učení umělou neuronovou síť (NN, z angl. neural network anebo artificial neural network). Slovo „neuronové“ v názvu vychází z inspirace propojení biologických neuronů do sítě v mozku. Architektura NN má totiž minimálně tři propojené vrstvy paralelně zapojených neuronů (nods): (i) vrstvu vstupů (input layer), (ii) skryté vrstvy (hidden layers) a (iii) vrstvu výstupů (output layer). Označení „hluboké“ se vztahuje k tomu, že moderní NN jsou vytvářeny několika desítkami až dokonce stovkami skrytých vrstev. Počet neuronů v jedné vrstvě a počet (skrytých) vrstev se liší v každém konkrétním modelu (jde o tzv. hyperparametr modelu) a závisí především na komplexitě modelovaného jevu. Každý neuron je napojen na každý neuron v další vrstvě a ve vrstvě předchozí. Díky tomu se v každé další vrstvě akumuluje výsledek i z předchozích vrstev NN. Neuron ve skryté vrstvě je definován lineárním prediktorem a nelineární aktivační funkcí. Proces učení pak probíhá podle zvoleného optimalizačního algoritmu iteracemi parametrů (vah) v jednotlivých vrstvách, dokud se nedosáhne kritéria, které proces zastaví (buď byla chyba predikce ve vrstvě výstupu vyhodnocena jako dostatečně malá anebo byl proveden maximální počet iterací). Optimalizace probíhá jinými slovy tak, že neuron dostane tím větší váhu, čím lépe přispívá ke správné odpovědi (čili výsledku blížící se pozorování vysvětlované proměnné v tréninkovém data setu).

V literatuře se skupina DL modelů dále člení na několik typů, z nichž některé velmi stručně uvedu, protože se v analyzované literatuře objevují:

- RNN (z angl. recurrent neural network) se typicky používá pro časové řady a sekvenční data (text, řeč), protože jsou uzpůsobené k tomu, aby si ve vnitřní paměti uchovala znalost o delším časovém úseku. (Sezer a kol., 2019, str. 8) Nevýhoda je v tom, že učení RNN „s dlouhou pamětí“ se stává velmi komplexní (je obtížné najít optimální váhy pro dlouhodobé vztahy).
- LSTM (z angl. long short term memory) je speciálním typem RNN, která je uzpůsobená tomu, aby si kromě dlouhodobých hodnot pamatovala i krátkodobé hodnoty díky kombinaci aktivačních funkcí. Kromě častého využití ve financích (finančních časových řadách) (viz Sezer a kol., 2019, Huang a kol., 2020 a Vachhani a kol., 2019) je dle (Sezer a kol., 2019, str. 9) LSTM široce využívána pro rozeznávání řeči, zpracování přirozeného jazyka, rozeznávání rukopisného textu apod.

Existují i další DL modely, ale protože se v analyzovaných článcích neobjevovaly, tak se jim v tomto článku nebudu detailněji věnovat.

Výhody:

- NN (především DL) dosahuje velmi vysokých ukazatelů přesnosti predikce (Ghoddusi a kol., 2019, str. 24). Pokud je k dispozici dostatek trénovacích dat, výpočetní kapacity a času, tak NN často překonávají jiné algoritmy. (Mueller a Guido, 2016, str. 119)

Nevýhody:

- Algoritmus DL je velmi netransparentní, takže jeho zdůvodnění (následná interpretace) je obtížné. (Ghoddusi a kol., 2019, str. 24)
- Vysoká náročnost na množství dat a proces učení. (tamtéž)
- Vysoké riziko přeučení se. (tamtéž)
- Nedokáže tolerovat chybějící hodnoty, irelevantní a redundantní proměnné. (tamtéž)

Rozvíjející oblastí ML výzkumu jsou tzv. hybridní modely (také ensemble models), které kombinují 2 a více samostatných predikčních modelů (lze přitom míchat ML a běžné statistické modely dohromady). Dle (Vachhani a kol., 2019, str. 2) jsou hybridní modely zpravidla založené na některém z typů NN modelu a ukazuje se, že hybridní modely přinesou slibné výsledky (Vachhani a kol., 2019, str. 5)

Preferované ML modely

Metastudie, která popisuje všechny typy ML modelů (Vachhani a kol., 2019), ukazuje relativně rovnoměrné rozdělení využití různých ML modelů a z nich nejčastěji SVM (23 %).

Většina zkoumaných metastudií se však soustředí na primární studie využívající pouze hluboké učení. Z toho se dá přinejmenším dovodit, že hluboké učení je momentálně vědecky

zajímavější. Dále mne zaujalo, že metastudie zaměřené na hluboké učení nejsou jednotné v tom, jaký ML model je preferován v primárních člancích. Není tedy možné identifikovat jeden nejspěšnější model na základě analyzovaných metastudií.

Z toho vyvozují, že neexistuje jeden „nejlepší“ ML model, ale že pro různá využití připadá různé, nebo i více možných modelů. Spíše je důležité zvážit výhody a nevýhody v konkrétní situaci (např. kvalita dat, velikost dat, zaměření na predikci, nebo interpretaci apod.). V praxi výzkumníci obvykle zpracují několik různých ML modelů. Jednotlivé modely pak mezi sebou porovnávají (někdy i vůči běžným statistickým modelům) a následně z nich vybírají ten, který v dané výzkumné otázce docílil nepřesnější predikce.

Sezer a kol., 2019, str. 40-41 se domnívají, že z části je volba použití ML modelů závislá také na popularitě (a úspěšnosti) v předchozích výzkumech.

Oblasti využití strojového učení ve financích

Ve financích podniku a jeho oceňování často vzniká potřeba predikovat budoucí hodnoty vybraných finančních ukazatelů na základě historických časových řad. Strojové učení je velmi silné ve vytváření predikcí, takže není překvapivé, že strojové učení je využíváno právě na predikce finančních časových řad. Zajímalo mne v jakých výzkumech konkrétně nachází strojové učení největší uplatnění.

Studie Sezer a kol., 2019, str. 39 a Kuizinienė a Krilavičius, 2020, str. 65 se shodují, že mezi aplikacemi jednoznačně převládá cíl predikovat ceny na kapitálovém trhu. Z analyzovaných 140 primárních výzkumů více než 70 % se zabývalo akciovým trhem, a to buď ve formě odhadu budoucí ceny konkrétní akcie, akciového indexu nebo odhadem budoucího pohybu cen akcií (Sezer a kol., 2019, str. 39)

Mezi další oblasti aplikace strojového učení patří také:

- Související s oceňováním jiných aktiv: komodity, dluhopisy, měnové kurzy a kryptoměny.
- Jiná finanční témata (Sellhorn, 2020): tvorba účetních odhadů, vyhodnocení kreditního rizika, detekce anomálií a odhad poptávky a nabídky. Protože tyto oblasti nespadají do mého zaměření na ocenění podniku, dále se jimi v tomto článku nebudu zabývat.

Akcie

Odhad budoucí ceny akcií patří snad mezi nejvíce zkoumané oblasti. (Sezer a kol., 2019, str. 17). Podle mého zjištění toto platí i o strojovém učení v oblasti financí podniku a jeho ocenění. Sezer a kol., 2019, str. 17, ukazují, že současný výzkum upřednostňuje spíše odhadování směru budoucího pohybu ceny (trend). Tento posun ve formulaci výzkumné otázky má vliv na metodologii strojového učení. Z technického pohledu se jedná o klasifikační úlohu (zjišťuje se, jestli cena poroste/klesne) místo regresní úlohy (hledá se kolik bude cena). Model i způsob vyhodnocení úspěšnosti se tedy bude lišit, ačkoliv z věcného hlediska je rozdíl spíše jen v interpretaci výsledků, neboť vysvětlovanou proměnnou ovlivňují stejné faktory (Sezer a kol., 2019, str. 32).

Ze zkoumaných studií vyplývá, že metodika se mezi články poměrně liší. Celkově lze učinit následující shrnutí:

- Vstupní data o tržních cenách akcií jsou z různě dlouhých období (obvykle 1 - 5 let nebo 15 - 25 let. Dle zjištění (Jiang, 2021, str. 16) souvisí volba délky období na frekvenci tržních dat (od vysokofrekvenčních denních až po měsíční data).
- Nejčastěji však jsem se setkala s denní frekvencí, a to obzvláště v novějších člancích (Jiang, 2021, str. 9).
- Data jsou za různý počet společností (obvykle desítky až stovky, ale objevují se i analýzy pro jednu nebo několik málo společností (viz Sezer a kol., 2019, str. 17-22), a to jak z rozvinutých trhů (především USA), tak i z rozvíjejících ekonomik (např. Čína) (Jiang, 2021, str. 10);
- Kromě tržních cen akcií se často v primárních studiích objevují i další vstupní data zahrnují například makroekonomická data, technické analýzy (i ve formě obrázků (viz Jiang, 2021, str. 13-14), fundamentální data, zprávy z Reuters a Bloombergu, příspěvky ze sociálních médií apod.
- Jiang, 2021, str. 20, zjistil, že nejčastěji se objevují čistě tržní ceny (36 % studií), následované kombinací tržních cen a technických indikátorů (25 %). Dle studie (Vachhani a kol., 2019) se pohybuje počet vysvětlujících proměnných v jednotlivých výzkumech kolem mediánu 6,5. Relativně nízký počet proměnných pravděpodobně ukazuje na riziko přeučení u ML, kterého se autoři studií snaží vyvarovat.

Akciové indexy

Predikce akciových indexů se ukazuje být rovněž relativně oblíbeným tématem. Výhoda použití akciových indexů (Sezer a kol., 2019, str. 23) ve výzkumu spočívá v tom, že jejich průběh je méně volatilní a více vypovídá o celkovém stavu ekonomiky. O analyzovaných výzkumech se dá obecně říci, že:

- nejčastěji jsou použita tržní data o akciovém indexu S&P500 a dále asijské indexy, např. Tokyo Nikkei Index (NIKKEI)225, The Korea Composite Stock Price Index (KOSPI), a Dow Jones Industrial Average (DJIA);
- obdobně jako u akcií, některé studie zahrnuly i dodatečné zdroje dat, se kterými jsou tržní data kombinována;
- horizont predikce opět převládá denní, ale častěji se objevují vícedenní (7 – 30 dní) u výzkumů zahrnující pouze vstupní data o akciovém indexu.

Ostatní typy aktiv

Relativně velkému zájmu (i když ve srovnání s akciemi výrazně menšímu) se těší predikce cen vybraných komodit (Sezer a kol., 2019, str. 27-28).

Díky vysoké likviditě trhu s měnami se také objevují výzkumy zahrnující predikce měnových kurzů, a to zpravidla v páru s USD, (Sezer a kol., 2019, str. 30). Nejčastěji se jedná

o jednodenní predikce (Sezer a kol., 2019, str. 29). Objevuje se také výzkum zaměřený na kryptoměny (zpravidla bitcoin). (Sezer a kol., 2019, str. 32).

Predikce cen dluhopisů zřejmě není obvyklá. Zmíněná byla pouze jedna studie (Sezer a kol., 2019, str. 28)

Může být strojové učení užitečné ve financích podniku a jeho ocenění?

Celkově se dá shrnout, že analyzované metastudie se většinou shodují, že strojové učení dosahuje v predikcích finančních časových řad nebývalé přesnosti. Zároveň lze také pozorovat, že používané modely jsou stále komplexnější (viz vývoj od jednodušších modelů jako SVM k neuronovým sítím až k hybridním modelům). Otázka je, jestli nejsou výzkumníci přehnaně optimističtí a jestli mají popisované modely šanci obstát v praxi.

Zajímavou diskuzi představil Buczynski a kol., 2021, str. 228-229. Namítají, že jestliže jsou ML algoritmy konzistentně schopné dosahovat predikční přesnosti nad 90 %, jak většinou tvrdí vědecké studie, pak by zákonitě i v investiční praxi mělo převládnout využití ML. Na základě jejich zjištění tomu tak není. Vychází přitom z informací o velikosti spravovaného majetku investory, kteří (deklarují, že) pro své rozhodování převážně využívají ML. Tuto hodnotu srovnává s hodnotou spravovaného majetku v celém odvětví investičního managementu (zjednodušeně jako 500 největších fondů). Uvedená čísla nechci přesně replikovat, protože sám autor přiznává, že vzhledem k obtížnosti získat spolehlivá data mu nejde o vyčíslení přesného podílu, ale o hrubou ilustraci toho, že se jedná skutečně o zanedbatelně malý podíl (na základě jejich údajů k roku 2017 méně než 1 %).

Osobně se domnívám, že pravda bude někdy mezi těmito dvěma póly: ML samo o sobě nebude schopno nahradit člověka v investičním rozhodování a ve financích podniku, ale určitě mu bude moci poskytnout zdroj dalšího pohledu na věc, který se může ukázat jako užitečný. Doporučuji téma využití strojového učení ve financích podniku a jeho ocenění dál sledovat.

Závěr

V tomto článku jsem se zabývala aplikacemi strojového učení ve financích, konkrétně pro finance podniku a jeho ocenění. Na základě rešerše současné literatury jsem se snažila poskytnout základní orientaci ve využití strojového učení ve financích podniku a jeho ocenění.

V rámci zvoleného tématu jsem pozorovala, že nejčastější oblastí aplikace v rámci financí je predikce budoucích cen aktiv, především akcií. Protože téma ocenění akcií je relevantní pro ekonomy působící v oblasti financí podniku a jeho oceňování, doporučuji vývoj v této oblasti dále sledovat. Vědecké výzkumy ukazují slibné výsledky, což prokazuje i velký počet nových článků na toto téma. Zdá se ale pravděpodobné, že na přechod z teorie do praxe ještě budeme muset čekat.

Literatura

- [1] Buczynski, W., Cuzzolin, F., a Sahakian, B. (2021): A review of machine learning experiments in equity investment decision-making: why most published research findings do not live up to their promise in real life. *International Journal of Data Science and Analytics* (11), P. 221-242. <https://doi.org/10.1007/s41060-021-00245-5>
- [2] Durairaj, M., & Mohan, B. K. (2019): A Review of Two Decades of Deep Learning Hybrids for Financial Time Series Prediction. *International Journal on Emerging Technologies*, 10(3), p. 324-331.
- [3] Ferreira, F. G., Gandomi, A. H., a Cardoso, R. T. (2021): Artificial intelligence applied to stock market trading: A review. *IEEE Access*, 9, 30898-30917.
- [4] Ghoddusi, H., Creamer, G. G. a Rafizadeh, N. (2019): Machine Learning in Energy Economics and Finance: A Review. *Energy Economics*, 81. Preprint. P 1-72 <https://doi.org/10.1016/j.eneco.2019.05.006>
- [5] Hastie, T., Tibshirani, R. and Friedman, J. (2001): *The Elements of Statistical Learning, Data Mining, Inference, and Prediction*. Springer, New York. ISBN 0-387-95284-5
- [6] Huang, J., Chai, J., a Cho, S. (2020): Deep learning in finance a banking: A literature review and classification. *Frontiers of Business Research in China*, 14:13, p. 1-24. <https://doi.org/10.1186/s11782-020-00082-6>
- [7] Jiang, W. (2021): Applications of deep learning in stock market prediction: recent progress. *Expert Systems with Applications*, 184: 115537. Preprint. P. 1-97. <https://doi.org/10.1016/j.eswa.2021.115537>
- [8] Kuizinienė, D., a Krilavičius, T. (2020): Deep learning methods application in finance: a review of state of art. In *CEUR Workshop proceedings [electronic resource]: IVUS 2020, Information society a university studies*, Kaunas, Lithuania, 23 April, 2020: proceedings. Aachen: CEUR-WS, 2020, Vol. 2698. p. 59-69.
- [9] Mueller, J. P., & Massaron, L. (2016): *Machine Learning for dummies*. John Wiley & Sons, New Jersey. P. 410. ISBN 978-1-119-24551-3
- [10] Müller, A. C., and Guido, S. (2016): *Introduction to Machine Learning with Python: A Guide for Data Scientists*, O'Reilly Media, Incorporated. ISBN 978-1-449-36941-5
- [11] Ozbayoglu, A. M., Gudelek, M. U., a Sezer, O. B. (2020): Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, 106384. Preprint. P. 1-52. <https://doi.org/10.1016/j.asoc.2020.106384>
- [12] Rundo, F., Trenta, F., Luigi di Stallo, A. a Battiato, S. (2019): Machine Learning for Quantitative Finance Applications: A Survey. *Applied Sciences*, 9(24), 5574. p. 1-20. <https://doi.org/10.3390/app9245574>
- [13] Sellhorn, T., (2020): Machine Learning und empirische Rechnungslegungsforschung: Einige Erkenntnisse und offene Fragen. *Schmalenbachs Z betriebswirtsch Forsch* 72, 49–69. <https://doi.org/10.1007/s41471-020-00086-1>
- [14] Sezer, O. B., Gudelek, M. U., a Ozbayoglu, A. M. (2019): Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, 106181. p. 1-63. Preprint. arXiv preprint arXiv:1911.13288.

- [15] Shah, D., Isah, H., a Zulkernine, F. (2019): Stock market analysis: A review and taxonomy of prediction techniques. *International Journal of Financial Studies*, 7(2), 26. p. 1-21. <https://doi.org/10.3390/ijfs7020026>
- [16] Singh, N.P., Som, B.K., Komalavalli, C. a Goel, H. (2021): A Meta-Analysis of the Application of Artificial Neural Networks in Accounting a Finance. *SCMS Journal of Indian Management*, 18(1), pp. 5-21.
- [17] Vachhani, H., Obiadat, M. S., Thakkar, A., Shah, V., Sojitra, R., Bhatia, J., & Tanwar, S. (2019): Machine learning based stock market analysis: A short survey. In *International Conference on Innovative Data Communication Technologies a Application*. Springer, Cham. P. 12-26.
- [18] Warin, T. a Stojkov, A. (2021): Machine Learning in Finance: A Metadata-Based Systematic Review of the Literature. *Journal of Risk a Financial Management* 14, no. 7: 302. P. 1-31. <https://doi.org/10.3390/jrfm14070302>

Může být strojové učení užitečné ve financích podniku a jeho ocenění? Přehled současného výzkumu

Veronika Staňková

ABSTRAKT

Predikce finančních časových řad je v centru zájmu vědeckého výzkumu po dlouhou dobu. Nedávno se k tomu přidaly široké možnosti aplikovat metody strojového učení. V současné době se publikuje tak velké množství vědeckých článků v oblasti aplikace strojového učení ve financích, že je velmi obtížné se v nich zorientovat. Cíl tohoto článku je poskytnout základní přehled o tom, jaký je současný stav poznání v této oblasti, konkrétně pro finance podniku a jeho ocenění, a pomoci se zorientovat v metodách strojového učení těm, kteří se doposud strojovým učením nezabývali.

Klíčová slova: Strojové učení; Hluboké učení; Finance; Akcie.

Can Machine Learning Be Useful in Corporate Finance and Business Valuation? Overview of Current Research

ABSTRACT

Prediction of financial time series has been at the centre of scientific research for a long time. Recently, there have been a wide range of possibilities to apply machine learning methods. Currently, there are so many scientific papers in the field of application of machine learning in finance that it is very difficult to find the way around. The presented paper aims to provide a fundamental overview of the current state of knowledge in this area, specifically within the area of corporate finance and business valuation, and to assist in orientation in the methods of machine learning those who have not yet encountered machine learning.

Key words: Machine learning; Deep learning; Finance; Shares.

JEL classification: G120