DIPLOMOVÁ PRÁCE

Prediktivní modely pro identifikaci a kalibraci klíčových faktorů úspěšnosti financování za pomoci crowdfundingu

Predictive models for identification and calibration of key success factors for financing with crowdfunding

STUDIJNÍ PROGRAM

Řízení rozvojových projektů

STUDIJNÍ OBOR

Projektové řízení inovací v podniku

VEDOUCÍ PRÁCE

Ing. Eva Cipovová, Ph.D.,

PROŠEK

DANIEL

2019

ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

ZADÁNÍ DIPLOMOVÉ PRÁCE

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: Prošek Jméno: Daniel Osobní číslo: 406394

Fakulta/ústav: Masarykův ústav vyšších studií (MÚVS)

Zadávající katedra/ústav: MÚVS ČVUT v Praze, oddělení ekonomických studií

Studijní program: Řízení rozvojových projektů

Studijní obor: Projektové řízení inovací v podniku

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Prediktivní modely pro identifikaci a kalibraci klíčových faktorů úspěšnosti financování za pomoci crowdfundingu

Název diplomové práce anglicky:

Predictive models for identification and calibration of key success factors for financing with crowdfunding

Pokyny pro vypracování:

CÍL: Cílem DP je sestavení prediktivních modelů pro analýzu faktorů ovlivňujících úspěšnost crowdfundingu (CF), jakožto nástroje financování.
PŘÍNOS: Přínosem práce je framework pro nastavení CF kampaní, zvyšující šanci na úspěšné financování touto cestou.
OSNOVA: 1. Úvod; 2. Teoretická část – crowdsourcing, crowdfunding, prognózování - kvantitativní metody, kvalitativní metody 3. Praktická část - výběr konkrétních prognostických nástrojů, data mining, benchmarking zvolených nástrojů 4. Závěr

Seznam doporučené literatury:

DRESNER, Steven. Crowdfunding: a guide to raising capital on the Internet. John Wiley, 2014. Bloomberg financial series.
ELLIOTT, Graham, C. W. J. GRANGER a Allan. TIMMERMANN. Handbook of economic forecasting. Elsevier North-Holland, 2013.
POURRET, O., Patrick, N a B. G. MARCOT. Bayesian networks: a practical guide to applications. John Wiley, c2008.
CHASE, Charles. Demand-driven forecasting: a structured approach to forecasting. John Wiley, c2009

Jméno a pracoviště vedoucí(ho) diplomové práce:

Ing. Eva Cipovová, Ph.D., MÚVS ČVUT v Praze, oddělení ekonomických studií

Jméno a pracoviště konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: 6. 12. 2017 Termín odevzdání diplomové práce: 4. 5. 2018

Platnost zadání diplomové práce: 30. 9. 2019

Podpis vedoucí(ho) práce | Podpis vedoucí(ho) ústavu/katedry | Podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

5. 11. 2018

Datum převzetí zadání

Podpis studenta(ky)

© ČVUT v Praze, Design: ČVUT v Praze, VIC

Prošek Daniel. Prediktivní modely pro identifikaci a kalibraci klíčových faktorů úspěšnosti financování za pomoci crowdfundingu. Praha: ČVUT 2019. Diplomová práce. České vysoké učení technické v Praze, Masarykův ústav vyšších studií.

MASARYKŮV ÚSTAV
VYŠŠÍCH STUDIÍ
ČVUT V PRAZE

Prohlášení

Prohlašuji, že jsem svou diplomovou práci vypracoval samostatně. Dále prohlašuji, že jsem všechny použité zdroje správně a úplně citoval a uvádím je v přiloženém seznamu použité literatury.
Nemám závažný důvod proti zpřístupňování této závěrečné práce v souladu se zákonem č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) v platném znění.

V Praze dne: 17. 01. 2019 Podpis:

Poděkování

Na tomto místě bych rád poděkoval Ing. Evě Cipovové, Ph.D., vedoucí mé diplomové práce, za podporu při její realizaci, a především za flexibilitu co se týkalo přístupu k volbě tématu a jeho zpracování.

Vřelé poděkování také patří dnes již, převážně, bývalým spolužákům z MUVS. Tato práce by bez jejich podpory možná nikdy nevznikla.

V neposlední řadě je na místě poděkování studijní referentce Jaroslavě Bradáčové, která mi nesčetněkrát pomohla se studijní logistikou.

Abstrakt

Cílem této diplomové práce je sestavení prediktivních modelů pro analýzu faktorů ovlivňující úspěšnost crowdfundingu jakožto nástroje financování.

Teoretická část se zabývá shrnutím možnosti financování podniku, se zaměřením na nově založené společnosti. Především se jedná o přiblížení různých způsobů získání kapitálu. Dále bude poskytnut úvod do crowdsourcingu a crowdfundingu, s detailnějším pohledem na jednotlivé možnosti financování podniku touto metodou. V neposlední řadě dojde k představení několika prognostických postupů Metodologie prognóz, tak i vypořádání se s nejistotou, hodnocení přesnosti atp.

Praktická část je syntézou teoretických poznatků. Konstrukce několika kvantitativních modelů a jejich aplikace na data spojená s crowdfundingem. Následně bude vyhodnocena přesnost modelů, doplněná o komentář napříč zkoumanými tématy.

Klíčová slova

crowdfunding, prognózování, financování, Bayesian network, logistická regrese

Abstract

The aim of this diploma thesis is a construction of predictive models for analysis of factors affecting success of crowdfunding as a financing instrument.

The theoretical part deals with summary of options for business financing, with focus on newly launched enterprises. Predominantly, the focus will be on outlining various methods of raising capital. Furthermore, the part will serve as an introduction to crowdsourcing and crowdfunding, with more detailed insights into individual uses for venture financing. Last but not least, you will be introduced to several forecasting processes. Methodologies of forecasting itself, as well as approach for handling uncertainty, accuracy Assessment, etc.

Practical part is a synthesis of the theoretical knowledge. Construction of several quantitative models and their application related to crowdfunding. Subsequently, the model accuracy will be assessed, with a commentary on subjects across the range of topics.

Key words

crowdfunding, forecasting, funding, Bayesian network, logistic regression

Obsah

Úvod **5**

1 Zdroje financování podniku **6**

1.1 Vlastní prostředky 8

1.2 Financování cizím kapitálem 8

1.2.1 Typy cizího kapitálu 9

1.2.2 Výhody a nevýhody vyžití cizího kapitálu 9

1.2.3 Zdroje cizího kapitálu 9

1.3 Financování vlastním kapitálem 16

1.3.1 Výhody a nevýhody financování vlastním kapitálem 17

1.3.2 Zdroje vlasního kapitálu 17

2 Crowdfunding **20**

2.1 Úvod do crowdsourcingu 20

2.2 Úvod do crowdfundingu 22

2.3 Varianty crowdfundingu 24

2.3.1 Odměnový crowdfunding 25

2.3.2 Investiční crowdfunding 28

2.3.3 Úvěrový crowdfunding 30

2.3.4 Charitativní crowdfunding 30

3 Forecasting **31**

3.1 Prognózování v praxi 32

3.2 Vypořádání se s nejistotou v prognózách 32

3.2.1 Bodový forecast 32

3.2.2 Predikční intervaly 33

3.2.3 Vějířové grafy 33

3.2.4 Hustoty pravděpodobností 33

3.3 Uplatnění lidské expertizy 34

3.4 Prognostické postupy 35

3.4.1 Nastavování cílů 36

3.4.2 Kvantitativní metody 36

3.4.3 Kvalitativní metody 42

3.5 Hodnocení prognózování 47

4 Analytický model prognózy úspěšnosti crowdfudingu **50**

4.1 Získání, validace a čištění dat 51

4.2 Parametrizace a disrketizace dat 52

4.3 Konstrukce modelu a testování 56
4.4 Benchmark – Logstická regrese 58
4.5 Diskuse 62
Závěr 64
Seznam použité literatury 65
Seznam obrázků 69
Seznam tabulek 70
Seznam rovnic 70
Prohlášení k použitým citacím 72

Úvod

Dnešní svět se potýká s nebývalou mírou decentralizace. Ať už se jedná o způsob, jakým cestujeme po městě, bydlíme v zahraničí, platíme na internetu, přispíváme na charitu. Nebo jen chceme opravit pár řádků počítačového programu na kterém zrovna pracujeme. Takzvaná sdílená ekonomika je přerod od univerzálních poskytovatelů komplexního balíku služeb na přehršle menších specializovaných článků řetězu. Stejně jako s každou změnou se nejedná o celospolečenskou cestu přímo vpřed či přímo vzad. Jde o cestu trochu šikmo a na vynášení soudů o sdílené ekonomice je tedy stále brzy. Zatím totiž nelze s jistotou říct, kam se tento trend bude vyvíjet.

Na druhou stranu, s nejistotou se společnost potýká každý den, a o budoucím vývoji sdílené ekonomiky vynášíme závěry vědomě i nevědomě. Každý člověk je tak de facto prognostik. Vtip je v tom, že k tomu někteří lidé přistupují více formálně než jiní, ale doposud nevznikl universální recept na to, jak se s budoucí nejistotou správně vypořádat. Ani tato práce si neklade za cíl problém definitivně vyřešit. Má spíše jen poukázat na možnosti prognostiky a najít praktické aplikace. Z tohoto důvodu se autoři rozhodli propojit moderní a odvěký problém a nabídnou náhled o pár kroků dál ve sdílené ekonomice.

Jedním z trendů společnosti je decentralizace finančních institucí, která byla patřičně akcelerována bankovní krizí koncem minulého desetiletí. Jendou z nejvíce dotčených skupin jsou začínající podnikatelé. Mnohdy lidé jsou bez velkého množství vlastního kapitálu. Od banky si půjčit nemohou, od rodiny nechtějí a od některých subjektů by neměli. Dav – masa lidi bez bližších vazeb – může být jednou z dalších možností. Mohou se zapojit velkým množstvím akcí, což bychom obecně nazvali crowdsourcingem. Nebo mohou jen poskytnout své disponibilní peníze, což nazýváme crowdfundingem. Zde popsaná situace je dalším pilířem této práce. Zaměřeném se na nové podnikatele na jedné straně a dav na straně druhé.

Jednou z možností, jak pomoci propojit dav a podnikatele, je pomoci jim lépe navigovat nejistotu. V praktické části této práce sestrojíme několik prognostických nástrojů, které by měli pomoci zvýšit šance konkrétního podnikatele na úspěch. Úspěch podnikatele následně bude i úspěchem zákazníků, obzvláště v případě, kdy jsou i finančními partery.

Teoretická část, která tomu bude předcházet si za cíl dá propojení poznatků z několika disciplín, které budou informovat nejen vlastní konstrukci aplikovaných nástrojů a širší veřejnosti poskytne náhled jak do možností předpovídání budoucnosti, a pochopení omezení těchto praktik, tak i přehled jakým způsobem začít nový podnik. Ať již s pomocí davu nebo klasičtější struktury.

V neposlední řadě je motivace pro vznik této práce internistická. Autoři volně navazují na jejich předchozí výzkum z oblasti financí a prognózování, ve snaze získat i poskytnout ucelený pohled na problematiku. Kde původní výzkum byl převážně kvalitativního charakteru, problematika této práce se primárně opírá o kvantitativní nástroje.

Struktura práce se dělí na úvod, následovaný třemi kapitolami teoretická části se zaměřením na financování podniku, crowdfundingu, respektive prognózování. Teoretická část je následována praktickou část, kde došlo k syntéze teoretických poznatků a sestavení prognostických modelů které jsou předmětem vlastního výzkumu této práce. Následuje diskuse výsledků těchto modelů a závěrečné shrnutí práce.

1 Zdroje financování podniku

Tato kapitola s bude zabývat jedním ze dvou základních obsahových pilířů diplomové práce – financováním podniku – což je také jeden ze zásadních předpokladů úspěšného fungování jakékoli business venture. Vzhledem k povaze práce bude výhradní důraz kladen na způsoby akumulace kapitálu, nikoli účetnictví a další aspekty spojené s penězi podniku.

Gene Wang, podnikatel a CEO People Power, identifikoval 4 zásadní podmínky pro každý úspěšný podnik, (Makonnen & Rogers, 2014)

- Nikdy vám nesmí dojít peníze („Never run out of money.")
- Znejte váš business a produkt jako své boty („Really understand your business or product.")
- Mějte dobrý produkt („Have a good product.")
- Nikdy vám nesmí dojít peníze. („Never run out of money")

Důraz na finanční prostředky krásně ilustruje starou lidovou moudrost, že jakkoli dobrý nápad je bezcenný, pokud ho člověk neumí prodat. Také, že každý business stojí a padá na svém cash-flow. Bohužel, dodržovat body 1 a 4 je v praxi těší než na papíře, a financování podniku je kontinuální záležitostí. Makonnen & Rogers, (2014) dlouhodobější povahu financování ilustrují na příkladu Googlu. Brin a Page, zakladatelé podniku, nejdříve plně vyčerpali své kreditní karty na nákup paměťových médií, které potřebovali do začátku. Následně získali 100 tisíc dolarů od Andy Bechtolsteima a 900 tisíc od rodiny, přátel a známých. První získaný venture kapitál (VC)[1] i následné IPO přišli až výrazně později, po třech, respektive osmi letech od založení podniku (Makonnen & Rogers, 2014). [2]

Rizikovost investování do start-upů a nových podniků je hlavním faktorem, který motivuje výše uvedené chování z druhé strany barikády – z pohledu investorů. Proporčně je úspěšnost nových podniků nevelká, tak se nelze divit, že si investoři pečlivě vybírají, kam vložit své peníze a kolik. Rodiny a přátelé, kteří by mohli být povolnější investovat právě do toho vašeho nápadu, pro změnu mívají značně omezenější prostředky (Makonnen & Rogers, 2014, str. 10).

Nový podnik je možné financovat řadou způsobů – vlastním kapitálem, cizím od lidí blízkých anebo penězi, ke kterým vás neváže nic osobního. GEM, organizace zabývající se globálním výzkumem podnikání, avizuje, že venture kapitál využívá jen 1 z 1000 amerických podnikatelů a 73 % úvodního financování poskytují lidé z vlastních zdrojů. Z formálních kanálů financování hrají stále prim bankovní úvěry a následně úvěry od nebankovních institucí (**Obrázek 1**) (Makonnen & Rogers, 2014).

[1] Pro potřeby této práce se budeme držet anglického termínu venture a (business) angel při rozebírání finanční problematiky. Dostatečně výstižný český termín pro obě označení doposud neexistuje.

[2] IPO = initial public offering = veřejná emise akcií firmy která se nově nechala kótovat na burze

Zdroj 1 (Makonnen & Rogers, 2014)

Banks	$179 billion	53%
Nonbanks	96 billion	29%
Angels	30 billion	9%
Venture capitalists	10 billion	3%
Other	20 billion	6%
Total capital	**$335 billion**	

Obrázek 1 Podíl externích zdrojů financování

Je také potřeba zmínit, že financování Angel/VC v nemalé míře připadá již existujícím podnikům, a tudíž je význam těchto zdrojů z agregátního podnikatelského pohledu ještě menší. Dalším faktorem je účinnost žádostí – kde z některých pramenů dostane podnikatel monetární prostředky snáze než z jiných.

Obrázek 2 poskytuje zjednodušenou představu o tom, v jakých fázích životního cyklu podniku je standardně poskytován a využíván jaký typ financování.

Zdroj 2 (Makonnen & Rogers, 2014)

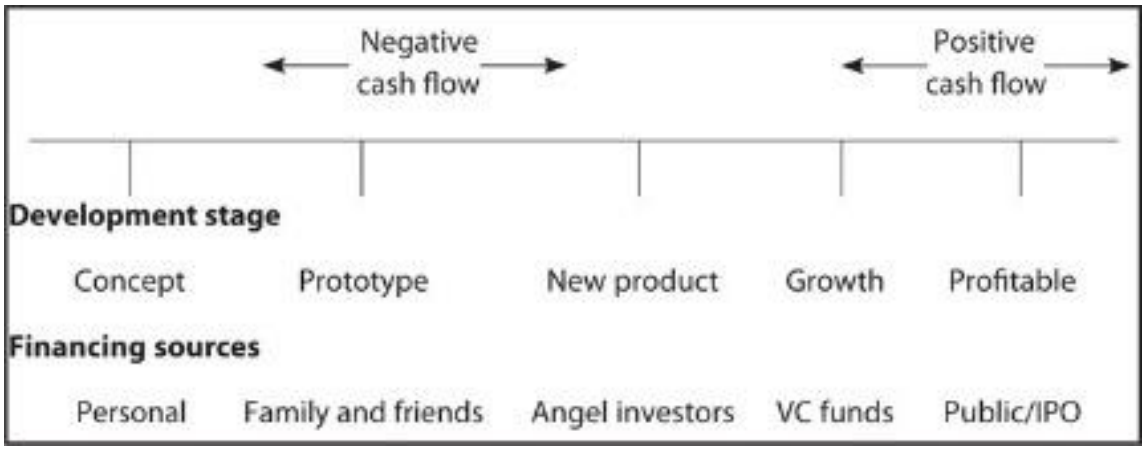

Obrázek 2 Způsoby financování vztažené k životnímu cyklu podniku

V následujících podkapitolách tato práce nastíní základní možnosti financování podniku. Rozlišujeme je primárně dle způsobu návratnosti investorům – investice do vlastního kapitálu podniku či půjčka, kde v prvním případě je protihodnotou vstupního kapitálu podíl na zisku a rozhodování v podniku, kdežto v druhém případě musí adresát vrátit získanou částku (včetně úroků) bez ohledu na osud podniku do kterého bylo investováno.[3]

[3] Toto je obecně platné tvrzení, ale ručení podniků za pohledávky se v praxi různí dle typu obchodní korporace, pod jakou je firma vedena, a dalších faktů.

1.1 Vlastní prostředky

Veřejnost si spojuje financování podnikání s penězi kde koho, jen ne podnikatelů samotných. Pravdou ale je, že většina prvotních finančních prostředků v podnikání jde z podnikatelovy vlastní kapsy (Barringer, Hess, Goetz, Ireland, & Moss, 2012, str. 10).
Makonen a Rogers (2014) citují GEP když tvrdí, že 73% prostředků financování start-upů kryjí sami zakladatelé, jelikož je získat peníze tímto způsobem snazší než od třetích stran, kvůli riziku[4]. (Makonnen & Rogers, 2014)

Spoléhání se ryze na vlastní kapitál se technicky nazývá „Bootstrapping." Rutherford (2015) definuje bootstrapping jako stav, kdy začínající podnikatelé řídí, mnohdy kreativně, své podniky bez pomoci cizího kapitálu. Ať už jeho dobrovolným odmítáním, či neschopností přilákat investory. (Rutherford, 2015)

Podnikatelům v této situaci lze doporučit aplikovat tzv. „lean startup" metodologie, např. (Ries, Vlaskovits, & Cooper, 2013) či (Ries, The Lean Startup, 2011). Ta sice neadresuje bootstrapping nebo frugal invoaci, ale sdílí princip efektivity, kde se podnik snaží dosáhnout maxima výsledků s minimem vynaloženého úsilí, respektive odpadu (včetně toho procesního)

Pár příkladů bootstrapingových technik: operace podniku z garáže či bytu rodičů, prodej auta, aby člověk financoval start-up, extrémní přesčasy namísto najmutí dalších zaměstnanců, financování podnikání pomocí konvenčního zaměstnání atp. (Rutherford, 2015)

1.2 Financování cizím kapitálem

Investopedia (2019) definuje dluh jako množství peněz půjčené jednou stranou od protistrany; využívané jednotlivci či korporacemi k velkým nákupům, které by si nemohli za normálních okolností dovolit. Dlužní smlouva umožňuje dlužníkovi půjčit si peníze s podmínkou, že budou zaplaceny zpět k pozdějšímu datu, zpravidla s úroky. Zjednodušeně řečeno se jedná o nástroj odložené splatnosti, která je vykoupena vyšší vratnou částkou oproti zapůjčené (úrok, zpravidla jako % navíc z původní částky). V praxi se jedná o komplexní smlouvy s klouzavou splatností (kreditní karty), zástavou (hypotéky), které mohou pozměňovat základní parametry takovéhoto vztahu (Investopedia, 2019).

Z výše uvedeného vyplývá, že investování tímto způsobem představuje fixní výnos pro věřitele a fixní náklad pro dlužníky. Teoreticky se tak nemůže stát, že by jedna strana musela poskytnout více či méně peněžních prostředků straně druhé. Nicméně z pohledu věřitele se nejedná o zcela bezrizikovou investici. Mnohdy se stává, že dlužník nemá dostatečné cash-flow na plnění svých závazků, a proto nevrátí předepsanou částku v plné výši. V praxi je riziko, že věřitel půjčené prostředky nesplatí vzhledem k možnému nedostatku finančních prostředků.

Vzhledem k jisté rizikovosti jsou indikátory zadluženosti jedním z klíčivých nástrojů finanční analýzy a investorů. Ti očekávají od podniku zadluženost menší než 4 EDITDA (Haggarty-Weir, 2017)[5] I podnikatel by měl toto hlídat, aby se nestalo, že jeho cash flow nebude dostatečné na krytí operativy a závazků.

---

[4] Netvrdíme, že založit podnik z vlastních peněz je bezrizikové, ale jen, že podnikatel sám vidí riziko vlastního počínání jinak než nezainteresovaná 3. strana.

[5] Ukazatel čistého dluhu vůči zisku (EBITDA): (krátkodobé pohledávky + dlouhodobé pohledávky – aktiva)/EBITDA

1.2.1 Typy cizího kapitálu

Fundamentálně rozlišujeme 4 typy zadluženosti – senior, subordinated, krátkodobá a dlouhodobá zadluženost. První dva druhy určují pořadí splatnosti závazků – věřitelé, kteří s vydobyli, že jejich závazek je typu senior (prioritní), budou vyplaceni přednostně před všemi ostatními v případě insolvence (neschopnosti splácet) obchodního subjektu dlužníka. Typ subordinated, také nazývaný mezanine kapitál, představuje závazky vyplácené až po plném vypořádání se se seniorními věřiteli, ale má stále přednost před výplatou vlastnických podílů. Klasifikace kapitálu tímto způsobem není závislá na pořadí investorů, ale na smluvní dohodě mezi stranami a souhlasu ostatních klíčových stakeholderů. Mezanine kapitál je zpravidla dražší, tzn. spojen s vyšší úrokovou sazbou než seniorní kapitál, jelikož je spjat s výším rizikem.

Senior a mezanine zadluženost společně s vlastním kapitálem představují kapitálovou strukturu podniku a vypovídají o způsobu, jakým je organizace jako celek financována.

Rozlišení cizího kapitálu na dlouhodobý a krátkodobý je dána časem splatnosti. První ze jmenovaných má být splacen za více než jeden rok, kdežto druhá kategorie představuje závazky se splatností na nejvýše 12 měsíců. Krátkodobé závazky jsou zpravidla spjaty s vyššími náklady a používají se na financování operativy podniku, kdežto dlouhodobý kapitál je zpravidla určen k investicím. Výjimkou jsou dlouhodobé závazky těsně před splatností, jelikož ty se z definice stávají krátkodobými, jelikož mají být splaceny v nadcházejících dvanácti či méně měsících) (Makonnen & Rogers, 2014).

1.2.2 Výhody a nevýhody vyžití cizího kapitálu

Barringer, Hess, Goetz, Ireland a Moss (2012) vidí hlavní výhodu využití cizího kapitálu ve faktu, že se vlastníci nemusí vzdát jakéhokoli podílu na vlastnictví společnosti. Za druhé je to daňová odpisovatelnost nákladů na úroky (ve srovnání s náklady na dividendy).

Za hlavní nevýhody považují samotnou povinnost splatit závazek, jelikož peníze jsou velice omezený zdroj v prvních měsících života podniku. Druhou nevýhodou je, že věřitelé zpravidla nastavují přísné podmínky půjček, aby chránili svou investici. Soukromý majetek podnikatele tak mnohdy musí posloužit jako zástava do rozjezdu podnikání. (Barringer, Hess, Goetz, Ireland, & Moss, 2012).

1.2.3 Zdroje cizího kapitálu

V následujících podkapitolách budou v kostce představeny způsoby financování podniků cizím kapitálem. Ačkoli crowdfunding je jedním ze zdrojů cizího kapitálu, bude mu věnována samostatná kapitola v další části práce.

1.2.3.1 Rodina a přátelé

Kiisel (2013), v souladu s ostatní zkoumanou literaturou, poukazuje na fakt, že rodina a přátelé jsou jedni z nejčastějších poskytovatelů finančních prostředků, 71 % podnikatelů v USA využívalo takto získaných peněz (Kiisel, 2013). Makonnen a Rogers (2014) nicméně také označují tento způsob získávání prostředků za nejméně žádoucí, a že by se mu podnikatel měl vyhýbat, pokud je to jen možné (Makonnen & Rogers, 2014).

Hlavní výhodou tohoto kanálu je menší formálnost a due dilligence se omezuje mnohdy jen na to, že rodič, sourozenec či strýc věří podnikatelskému záměru. Na druhou stranu četné problémy mohou vyvstat, když si onen blízký člověk neuvědomuje rizikovost investice, jeho očekávání se neslučují s podnikatelem, či se změní životní situace a potřebuje peníze vrátit dříve. Ve všech těchto případech riskuje dlužník nezvratné poškození osobních vazeb, nejen vazeb obchodních což má mnohdy dopady na celý okruh rodiny a přátel. Někdo najednou nemusí dorazit na díkuvzdání či společné vánoční oslavy (Kiisel, 2013).

Pokud není zbytí, tak Makonnen a Rogers dále navrhují čtyři pravidla, kterých by se měl podnikatel držet:

- Řekněte si o peníze jen těm [příbuzným a přátelům], kdo si opravdu můžou dovolit přijít o celou investici, a dopodrobna vyličte rizika.
- Sepište detailní dlužní smlouvu.
- Umožněte investorovi přetavit investici z dluhu na podíl ve firmě.
- Osobně přislibte, že vrátíte celou půjčenou částku plus bezrizikovou prémii, jakožto naprosté minimum.

(Makonnen & Rogers, 2014)

Hawkley a Cacioppo {2012} (identifikovali negativní korelaci mezi zdravím jednotlivců a pocitem samoty, jak na základě vlastního výzkumu, tak i studiem dostupné literatury. Kde se oni zabývali do velké míry mezi fyziologickými vlivy samoty na zdraví, Ypsilanti, Lazuras, Powell, a Overon (2019) zkoumali vztah mezi samotou a depresí. Jelikož lze snadno spojit zdravotní problémy a konzumaci léků, lze také usuzovat, že samota vlivem poškození sociálních sítí v důsledku podnikání může nepřímo vést k větší konzumaci podnikatelem (Hawkley & Cacioppo, 2012), (Ypsilanti, Lazuras, Powell, & Overon, 2019). Jelikož se velikost trhu s farmaceutiky odhaduje na 935 miliard dolarů v roce 2017 a 1170 miliard dolarů v roce 2021, tak nelze poukázat i na přímé negativní finanční dopady na špatné zdraví (The Business Research Company, 2018). K zamyšlení, a případně další výzkum je, jestli se nakonec vyplatí riskovat osobní vztahy kvůli financím, když by byly zohledněny i možné negativní finanční dopady přerušování sociálních vazeb.

1.2.3.2 Kreditní karty

Kreditní karta je platební karta, kterou vydavatel umožňuje uživateli půjčovat si prostředky k platbě za zboží a služby, za podmínek, že půjčená částka a další [smluvní] poplatky budou zaplaceny. Kreditní karty se zpravidla pojí s vyšší úrokovou sazbou než ostatní spotřebitelské úvěrové produkty, ale na druhou stranu je účtování úroků zpravidla odložené o předem dohodnutý časový úsek[6] (Investopedia, 2019).

Barringer, Hess, Goetz, Ireland a Moss (2012) citují osobní kreditní karty jako nejčetnější zdroj cizího kapitálu v prvním roce životnosti podniku, 30,2 % podniků využívá tento způsob financování (Barringer, Hess, Goetz, Ireland, & Moss, 2012). Makonnen a Rogers (2014) ale varují, že dluh spojený s kreditní kartou může být jednou z nejsnazších a nejrychlejších cest k bankrotu podnikatele. Nicméně citují i výhody a důvody, proč se kreditní karty těší takové popularitě mezi podnikateli. Za prvé, je snadné je získat a umožňují podnikatelům přístup k až 100 000 dolarů bez nutnosti vysvětlovat, jak bude s penězi naloženo. Malé podniky, které nesplňují podmínky pro bankovní úvěry, je využívají k financování růstu. Na závěr také říkají, že při obezřetném a metodickém využívání mohou být cestou k levnému kapitálu. Některé karty mají počáteční úrokové sazby i 0 %, a mohou být zdrojem bezúročného krátkodobého financování. Na rozdíl od obecné definice krátkodobého kapitálu, je zde termín chápán jako bezúročná smluvní doba spojena s kreditní kartou, např. splácení každý měsíc. Nicméně u druhého bodu je potřeba si dávat obzvláště pozor, jelikož poplatky z prodlení mohou být velmi vysoké a pro podnik může být náročné každý měsíc provádět velkou jednorázovou platbu ke konkrétnímu termínu vzhledem k standardní cash-flow situaci v nově založených podnicích (Makonnen & Rogers, 2014).

Mnohdy opomíjenou skrytou výhodou kreditních karet je možnost si vybudovat solidní kreditní historii, a tím se například kvalifikovat pro bankovní úvěr. Za předpokladu, že podnikatel má dostatečnou disciplínu pro financování touto cestou a vyvaruje se rizikovému chování. V opačném

[6] Jak bylo nastíněno výše, kreditní karta je zpravidla chápána jako spotřebitelský, nikoli podnikatelský produkt.

případě může mít i jedna opožděná platba zcela protichůdný dopad, než bylo zamýšleno (Glantz, 2014).

1.2.3.3 Tradiční úvěry

Data, např. **Obrázek 1,** umisťují banky, respektive úvěry, na jednu z předních příček financování malých a středních podniků. Špatnou správou pro podnikatele ale je, že s výjimkou zajištěných úvěrů (kapitola **1.2.3.6**) je šance dosáhnout na úvěr v nejrannějších fázích obchodní korporace malá. Na tomto se dostupná literatura univerzálně shoduje – např. (Anrold & Harzog, 2009), (Gregosn, 2014), (Glantz, 2014) a další.

Jedním z důvodů je algoritmická povaha přidělování úvěrů, kde se berou v potaz příjmy a výdaje, pracovní kapitál dlouhodobý hmotný majetek pro výpočet toho, kolik je možné půjčit. Začínající podniky, s minimálním majetkem, tak nemají prakticky šanci získat půjčku čistě na základě těchto kritérií. V posledních letech si sice banky s podnikateli více rozumí, ale i tak se podnikatel nevymaní z tradičních požadavků, vzhledem k tomu, že vyhodnocení čistě kapitálové struktury na dosažení na úvěr nestačí – hodnocení kredit ratingu subjektu, seznámení se s business plánem a majetku strukturou podniku, včetně její likvidity. Krom toho se pojí takřka každý úvěr s kolaterálem, mnohdy osobního majetku podnikatele – v roce 2006 tomu bylo v 90 % případů a není důvod si myslet, že by se tento trend měnil. V kostce se dají kritéria zohledňovaná při žádosti úvěru shrnout do 5C (**Obrázek 3**). (Makonnen & Rogers, 2014)

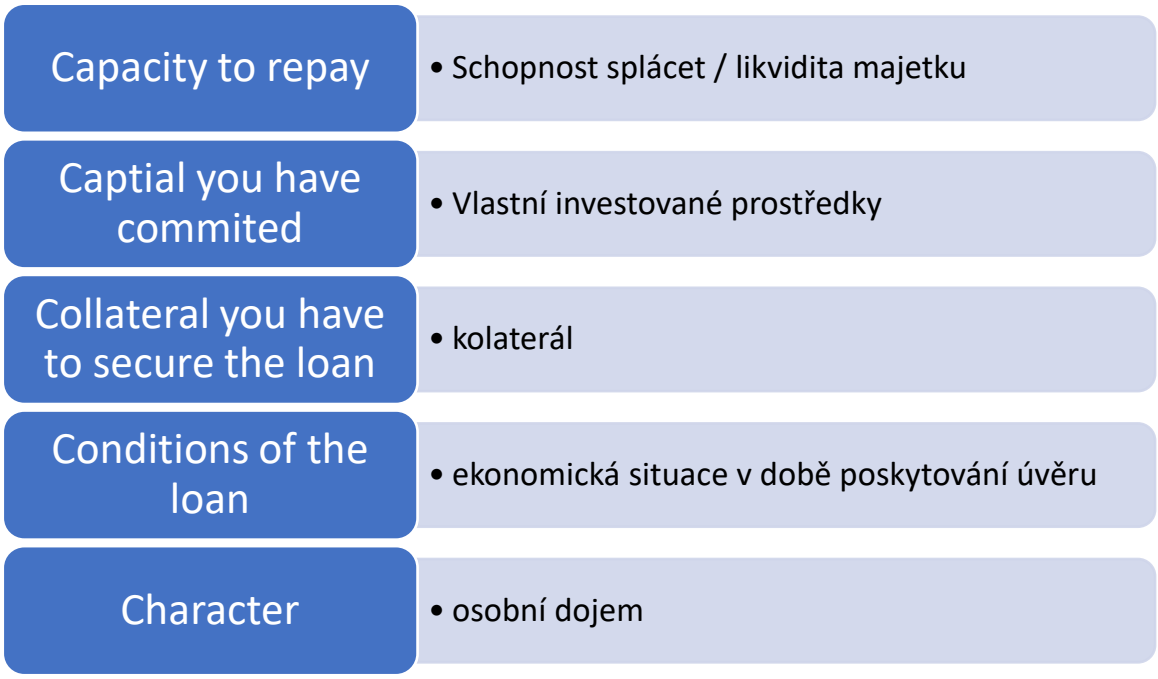

Obrázek 3 5C pro posuzování žadatele o bankovní úvěr

zpracováno podle: (Makonnen & Rogers, 2014)

Jak je vidět, tak se banky z části pořád drží tvrdých dat, ale také přihlíží k podnikatelově důvěryhodnosti a míře osobního rizika které na sebe bere. Ještě o něco vstřícněji se mohou chovat komunitní banky, ve srovnání s velkými bankovními domy. Zpravidla se jedná o nezávislé finanční instituce, které poskytují cílené úvěrové produkty. Mohou tak mít jak větší obeznámenost s lokálně geo-politickou situací a vyznat se v konkrétní obchodní vertikále, a následně mít přesnější obrázek o rizikovosti konkrétního podnikového záměru. Za druhé, jejich velikost nahrává osobnějšímu přístupu ke klientům. (Makonnen & Rogers, 2014)

1.2.3.4 Angels

Business Angels jsou zpravidla movití jedinci, kteří investují do podniků ze svých osobních peněz, namísto v zastoupení nějakou institucí. Mnohdy se jedná o úspěšné podnikatele, kteří dál působí ve své doméně expertizy i nad rámec jejich vlastních podniků. Tradičně se sice jedná o ekvity investory, ale v poslední době se někteří zaměřují i na debt-financing.

Jelikož se jedná o jednotlivce, kteří investují, tak jsou mnohem flexibilnější, co se podmínek a poskytování úvěrů týká, na rozdíl například od bank. Legislativní rámec je omezuje jen z části a nejsou vázáni korporátními stanovami, takže hlavním kritériem pro to, jestli investovat nebo ne je pro ně jejich vlastní úsudek. Nicméně, je potřeba si neplést flexibilitu a selektivitu – investice směřují i tomu, komu by banka nikdy své peníze nesvěřila, tak si Angel pořád důsledně vybírá jakožto profesionál. Za další, flexibilita je vykoupena cenou. Není neobvyklé, že Angel investor půjčuje s roční úrokovou sazbou 24 %, což několikanásobně převyšuje obchodní úvěrové sazby ale dokonce i úroky na některých kreditních kartách. (Makonnen & Rogers, 2014)

1.2.3.5 Nadace

Zajímavým zdrojem financování mohou být filantropické organizace – Ford foundation, MacArtthur Foundtion, atp. Původně poskytovali prostředky jen non-profit entitám, ale to se začalo měnit v 90. letech minulého století. Dnes operují spíše na for-benefit principu, kde společnosti mohou generovat profit za předpokladu, že jejich primární motivací není zisk ale společenské dobro. Společnosti zaměstnávající bývalé vězně, poskytování vzdělání, energetické podniky zabývající se obnovitelnými zdroji, budování infrastruktury v rozvojových zemích atp. Nadace jednak nabízejí kvalifikovaným podnikům úvěry a také poskytují granty takzvaným CDC organizacím.[7] CDC následně využívá tyto peníze k poskytováním půjček firmám zabývajícím se společenským dobrem. (Makonnen & Rogers, 2014)

Souboru půjček a dalších finančních instrumentů pro podporu „charitativního“ podnikání se říká buď *impact investment*[8] nebo *program-related investment*[9].

[7] CDC = community development Corporation (korporace pro rozvoj společnosti)
[8] https://www.macfound.org/programs/program-related-investments/
[9] https://grantspace.org/resources/knowledge-base/pris/

Bhartiya Samruddhi Investments and Consulting Services

Hyderabad, India

BRIDGE Housing Corporation

San Francisco, California

Cooperative Housing Foundation

Silver Spring, Maryland

Corporation for Supportive Housing

New York, New York

Enterprise Corporation of the Delta

Jackson, Mississippi

MBA Properties

St. Louis, Missouri

MacArthur Foundation

Chicago, Illinois

Peer Partnerships

Cambridge, Massachusetts

Shorebank

Chicago, Illinois

Wieboldt Foundation

Chicago, Illinois

Obrázek 4 Imact investment instituce *Zdroj: (Makonnen & Rogers, 2014)*

Hlavním benefitem pro podnikatele je nízký úrok, až 1% s 10-letou životností úvěru. Část nadací také poskytuje „smart money“, neboli peníze s přidanou hodnotou, jak bude pospáno v podkapitole **1.3.1.**

1.2.3.6 Zajištěné půjčky

Zajištěnými půjčkami zde nazýváme takové úvěrové produkty, které jsou poskytovány tradičními institucemi, ale část rizika na sebe bere např. vláda instance nadnárodního sdružení států (EU), atp.

Ve Spojených státech se jedná o *SBA (small business administrative loan).* Jedná se půjčky, kde vláda USA jistí úvěry poskytované bankou, či jinou konvenční institucí, což umožňuje poskytnutí úvěru širší paletě žadatelů díky přenesenému riziku, Takto si úvěr může vzít i podnik, kde majitel nemá dostatečnou kreditní historii či majetek jako kolaterál. Tento typ půjčky tedy využívá bankovní infrastruktury a státních peněz jakožto pobídky pro podnikatele. Nicméně, pokud má business možnost dosáhnout i na tradiční finanční nástroje, tak je možné, že nebude kvalifikovaný pro úvěr dle SBA regulace (Glantz, 2014). I když stát kryje 85 % rizika půjčky, tak to neznamená, že když podnikatel neplní závazky tak vyvázne bez postihu. Zpravidla je zde ručení osobním majetkem na oněch posledních 15 % krytých půjčující institucí, která se také pokusí vymoci maximum z půjčené částky, než se obrátí na stát. Instuce s příliš vysokýcm default-ratem přijdou o licenci na poskytování SBA půjček[10] (Makonnen & Rogers, 2014).

[10] Default = nesplácení závazků

Na rozdíl o nadačního financování, jsou SBA poskytovány jen for-profit podnikům, které spadají velikostně do parametrů uvedených na www.sba.gov, dle jejich odvětví. Dále podmínky vylučují několik oblastí podnikání jako hazard, pojišťovnictví, finanční produkty nebo firmy napojené na náboženské organizace a podniky vlastněné neamerickými občany. (Administration, 2019)

Na poli Evropské Unie se jedná o financování z peněz evropského rozpočtu, tzv. evropských fondů. Jak ilustruje **Obrázek 5**, základní fungování programu je stejné jako v případě SBA – vládní/nadvládní peníze tečou z rozpočtu koncovému adresátovi přes zprostředkující organizaci, jakou je banka či jiná akreditovaný organizace.

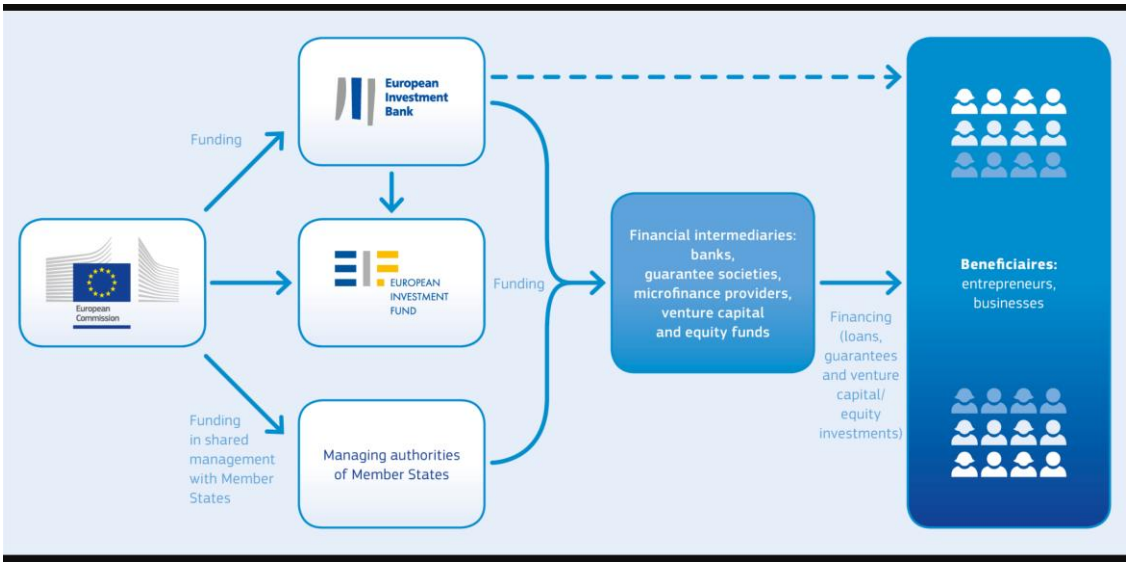

Obrázek 5 Schéma fungování evropských fondů

zdroj: (European Union, 2019)

Na rozdíl od SBA je evropský framework otevřen podnikům jakéhokoli zaměření a velikosti, s tím že poté záleží na konkrétní iniciativě EU, jakými pravidly se bude přidělování financí řídit a jaké množství financí je k dispozici. Na druhou stranu bychom rádi zmínili, že oba zde probírané programy poskytují nejen úvěry, ale i jiné formy financí, kterými se tato práce vzhledem k zaměření nezabývá.

Přímým evropským protipólem k SBA je program COSME, jehož jedním pilířem je právě poskytování jistin úvěrovým zprostředkovatelům půjčujícím malým a středním podnikům (SME). Druhým pilířem je nástroj kapitálového investování pro stimulaci růstu tohoto typu podniků. (Commision, 2019)

Druhým konkrétním nástrojem EU pro podporu SME je *SME Instrument*, což je třífázový nástroj podpory financování. Nejedná se sice a úvěrový produkt, ale zmiňujeme jej pro celistvost prezentovaných informací.

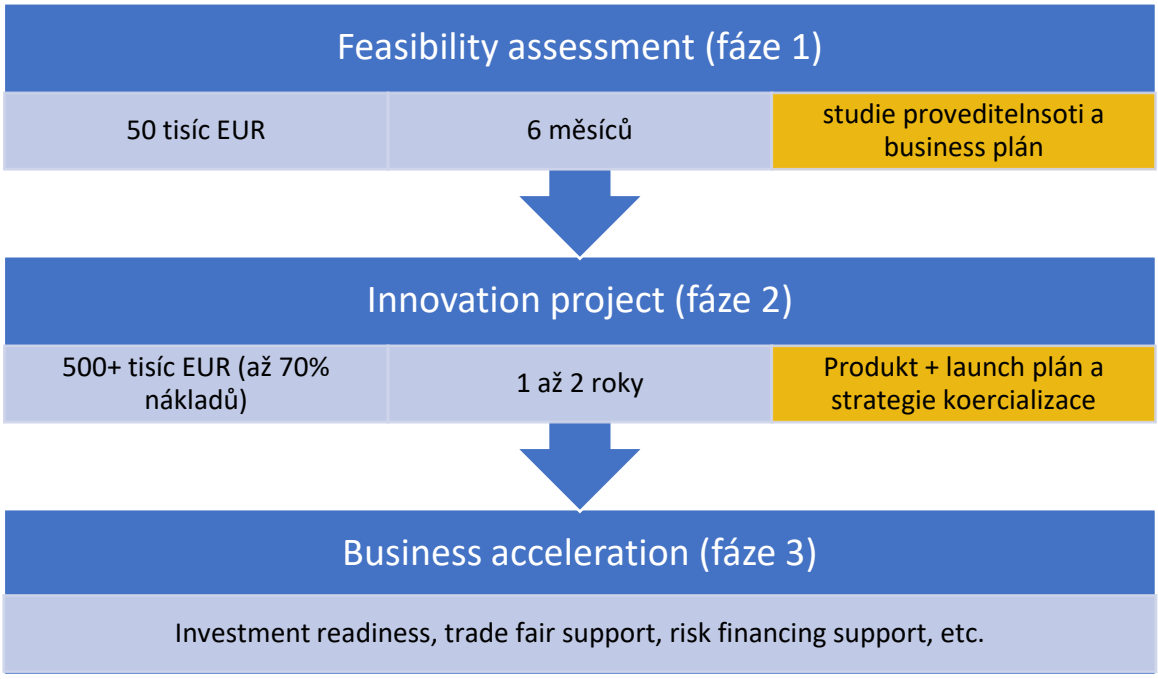

Obrázek 6 Struktura instrumentu SME

zpracováno podle: (Commission, 2019)

SME instrument doprovází podnik od úvodní stude proveditelnosti, kterou financuje, přes vývoj produktu a plánu uvedení na trh, kde kryje náklady, až po následnou akceleraci podniku, kde EU především pomáhá s integrací do odvětví. Mimo to jsou fáze 1 a 2 doprovázeny coachingem, který rozšiřuje podnikové know-how na poli inovací (Commission, 2019).

1.2.3.7 Person-to-person půjčky

Person-to-person neboli peer-to-peer (P2P) půjčování je decentralizovaná forma poskytování finančních prostředků jedním konkrétním člověkem jinému konkrétnímu člověku. Obecně lze potom P2P definovat jako proces, kdy věřitel a dlužník dojdou k finanční dohody bez účasti finanční instituce jako prostředníka. (Glantz, 2014)

P2P půjčování je produktem boomu sdílené ekonomiky posledních let. Služby dříve poskytované velkou instancí jsou dnes decentralizovaně poskytovány jednotlivci mezi sebou, zprostředkovaně online platformou. Role zprostředkovatele tak zcela nevymizela, ale zásadně se změnila – namísto služby samotné nabízí jen prostor pro ostatní k nákupu a prodeji. (Kiisel, 2013). Z podstaty tudíž P2P podléhá jiné dynamice než konvenční instrumenty.

Hlavními rysi P2P tak jsou

- Výhradně online operace
- Stát nepojišťuje finance (na rozdíl od bank)
- Úrokové sazby jsou na dohodě, nikoli fixně nebo algoritmicky determinované
- Půjčování má sociální rozměr – jedná se o interakci mezi 2 lidmi, nikoli „korporací bez tváře“ na jedné straně.

- Špatný kredit vede k vyšším nákladům (pořád však lepší než mnohé nebankovní produkty)[11],[12]

(Anrold & Harzog, 2009).

I když P2P není primárně nástroj financování podniků, tak se jedná o 2 nejčastěji uvádění důvod, proč se na tyto platformy jednotlivci obracejí. Pokud se nejedná o kapitálově náročný podnik, tak se zde dá usilovat o financování jak pro založení podniku, tak i jeho rozšiřování či krytí existujících operativních nákladů (Anrold & Harzog, 2009). Především pro podnikatele, kteří nemají přístup k tradičnímu úvěrovém financování, ekvity investorům a nechtějí si půjčovat od rodiny a přátel.

Protipólem jisté vyšší flexibility při získávání peněz, je větší rigidita poté co je dohoda uzavřena. Na rozdíl od ostatních půjček, je zpravidla vždy potřeba splácet měsíčně a dodatečné změny podmínek úvěru jsou takřka vyloučené. (Makonnen & Rogers, 2014). Autoři také dodávají, že P2P spoléhá na účastníky transakce, kteří mohou postrádat expertizu pro vyhodnocení schopnosti splácet a (Chen, Zhou, & Wan, 2016), (Mingfeng, Viswanathan, & Prabhala, 2009) poukazují na informační asymetrii u tohoto typu transakcí, která může mít negativní dopady na jednu či druhou stranu.

Jelikož je P2P přímou mezilidskou transakcí, zprostředkovanou přes internetové stránky, tak krom zohledňování finančních kritérií přihlíží poskytovatelé prostředků i k méně objektivním datům. Vyzdvihnul bych roli atraktivity člověka, kde hezkým lidem může jejich fotografie na profilu P2P stránky pomoci snáze získat úvěr. (Jin, Shang, & Qingguo, 2019) dospěli k závěru, že atraktivní lidé působí důvěryhodněji, a tudíž snáze dostanou půjčku. Na druhou stranu, jejich výzkum také ukázal, že věřitelé do větší míry tolerují nesplácení (či jinou neupřímnost) atraktivních lidí, ve srovnání s neatraktivními. (Jia, Fan, Dai, & Ma, 2017)[13] také dokázali, že tolerance vůči špatnému chování atraktivních lidí při P2P půjčování je vyšší než u lidí neatraktivních, a že krásní jedinci mají lepší podmínky. Nicméně, tyto 2 výzkumy se nejodují v interpretaci motivace, a stejně jako širší literatura předkládají že atraktivní lidé jsou důvěryhodnější, a že tomu tak není. Podobný výzkum, i když na jiné P2P doméně, provedli (Jaeger, Sleggers, Evans, Stel, & van Beest, 2018) obdobný výzkum, jejichž závěty se shodují s předchozím. V tomto případě byly zákazníci AirBnB ochotni pronajmout si dražší nemovitost od atraktivního hostitele ve srovnání s méně atraktivním. Z tohoto lze vyvodit, že P2P je z pohledu podnikatele rizikovější pro ty, kteří jsou méně atraktivní, jelikož je větší šance agresivního vymáhání pohledávek věřiteli při zpoždění se se splátkou.

1.3 Financování vlastním kapitálem

Neméně důležitý než cizí kapitál, je kapitál vlastní. V této kapitole se budeme zabývat nejrozšířenějšími metodami získávání vlastního kapitálu z vnějších zdrojů – business angels a venture kapitálem. Bootstrappingu, což je využití ryze vlastních prostředků již byla věnována podkapitola **1.1**, crowdfunding bude přiblížen dále a investice od rodiny a přátel je doporučená formou cizího kapitálu, s převoditelností na vlastnický podíl, jak probíráno v kapitole **1.2.3.1**.

---

[11] Úroková sazba několika poskytovatelů osciluje okolo 40 % (Peníze.cz, 2019)

[12] Např. https://www.lendingclub.com/public/rates-and-fees.action

[13] Jia Jin se podílel na obou zde zmiňovaných výzkumech. Nicméně, zbytek autorů se různil a jejich závěry jsou konsistentní obecně jak se 3. citovaným článkem tak i širší literaturou na toto téma.

Vlastní kapitál jsou finanční prostředky, které do podniku investují zakladatelé a další strany výměnou za vlastnický podíl, zpravidla bez jiné návratnosti.[14] (Green C. , 2011)

1.3.1 Výhody a nevýhody financování vlastním kapitálem

Stejně jako při financování cizím kapitálem, má tato forma několik výhod a nevýhod pro zakladatele podniku. Níže využijeme shrnutí výhod a nevýhod od (Barringer, Hess, Goetz, Ireland, & Moss, 2012)

Hlavní vnějších investic do vlastního kapitálu je ztráta části vlastnictví společnosti zakladateli. S tou jde ruku v ruce i ztráta části kontroly nad podnikem, což v důsledku může vést i k jinému organizačnímu směřování, než jaký by si zakladatelé představovali. Za druhé je vlastní kapitál zpravidla dražší než kapitál cizí. (Makonnen & Rogers, 2014)

Hlavní výhodou je množství dostupného kapitálu pro konkrétní podnik. Proto jsou tyto investice hojně vyhledávány podniky, s vysokými počátečními náklady. Za další, se jedná o expertizu a podporu investorů, jelikož mají jako vlastníci zvýšený zájem o úspěchu firmy. Tento fenomén se nazývá „value-added investment[15]“ Sice se nejedná o výhradní doménu angels a VC investorů, ale je to s nimi nejčastěji spojováno (Makonnen & Rogers, 2014). V neposlední řadě je výhodou, že podnikatel nemusí vracet žádné peníze – investoři generují zisk výplatou dividend a prodejem podílu (akcií atd.) v podniku.

1.3.2 Zdroje vlasního kapitálu

Jak již bylo nastíněno tato práce se bude soustředit na 2 základní formy investic do vlastního kapitálu, a např. IPO či jiné jsou zcela vynechány pro jejich marginalistu z pohledu počátečního financování podniku.

Pro souhrnnější pohled na získávání prostředků pomocí vlastního kapitálu doporučuji publikaci *„FInancing New Ventures“* (Gregosn, 2014), ze které bychom chtěli vyzdvihnout schéma popisující kroky které musí každý podnikatel provést, aby získal investici do cizího kapitálu (**Obrázek 7**).

[14] Jinou návratností rozumíme splátky pří financování cizím kapitálem. Vlastníkům připadají peníze ze zisku podniku., respektive z prodeje podílu v něm.

[15] Také se lze setkat s označením „smart-money“

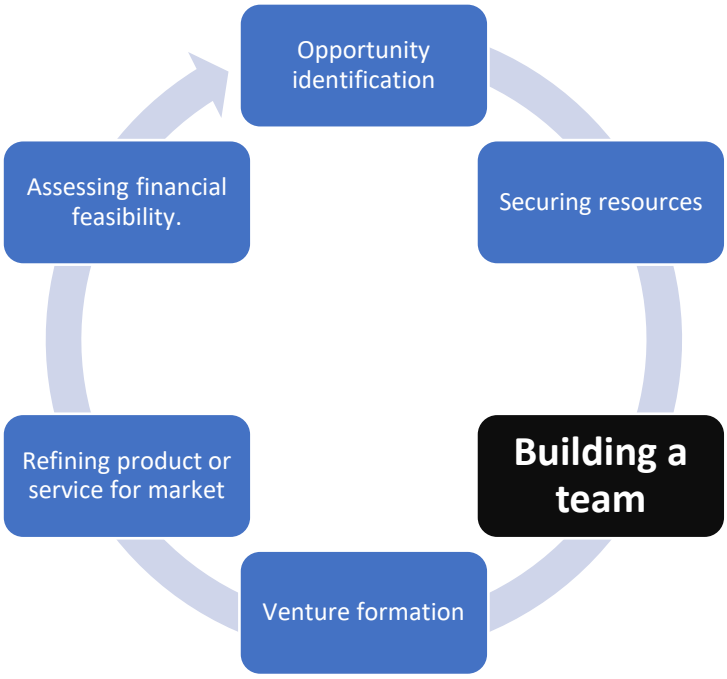

Obrázek 7 Klíčové aktivity nového podniku

(Gregosn, 2014)

Většina kapitálových investorů totiž považuje management podniku za nejdůležitější kritérium pro rozhodování o investici. Velkého důrazu se těší nejen předchozí podnikatelské zkušenosti, ale i osobní rysi jako pracovní morálka, integrita, schopnost týmové práce a odhodlání. Někteří podnikatelé se dokonce těší takové důvěře, že investice může být svázána přímo s nimi a nikoli konkrétním podnikem. V těchto případech jsou finance poskytnuty dopředu, aby podnikatel něco „vymyslel a rozjel." (Makonnen & Rogers, 2014)

1.3.2.1 Angels

Business angels jsou jedinci, kteří přímo investují své peníze do nových podniků. Typicky se jedná o 10 až 500 tisíc dolarů na podnik, a očekávají agresivní růst 30 až 40 procent za rok, před tím, než podnik přejde na burzu nebo je prodán. Jefferey Sohl, ředitel Centra pro Podnikový výzkum university v New Hampshire, odhaduje, že jen 10 až 15 % podniků splňuje tyto podmínky. Pokud podnikatelský záměr nesplňuje kritéria růstu, tak je ještě šance, že se shoduje se zájmy investora. Například, pokud se zaměřujete na výrobu autosedaček narazíte na investora s opravdových zájmen o dětskou bezpečnost, tak můžete získat prostředky i když od vašeho podniku nelze očekávat růst přes 30 procent za rok.

Většina angel investorů operuje anonymně, a propojují se s podnikateli na základě osobních referencí. Podnikatel, který má zájem o tento způsob financování by se tak měl aktivně zaměřovat na networking. (Barringer, Hess, Goetz, Ireland, & Moss, 2012)

1.3.2.2 Venture capital

Druhým typem equity investic je Venture kapitál. Firmy zabývající se venture investováním jsou společnosti profesionálních investorů, kteří získávají peníze soustřeďované do fondů jejichž využitím je investování do start-upů a rostoucích podniků. Příklady nejznámějších firem v této sféře jsou Kleiner Perkins, Sequio Capital, Redpoint Vetnures či fond spadající pod Tencent Holdings. Podobně jako business angels, venture kapitál fondy hledají meziroční růst firem, do kte-

rých investují kolem 30 až 40 procent. Hlavním rozdílem mezi těmito 2 pak je, že Angels častěji poskytují seed funding[16] kdežto venture fondy investují primárně až v o něco pozdějších fázích životního cyklu organizace (poté co je možné ověřit životaschopnost firmy). Také zpravidla neinvestují méně než 1 milion dolarů. Důsledkem toho je vhodnost vyhledávání investice formou venture kapitálu omezená jen na úzký profil podniků. (Barringer, Hess, Goetz, Ireland, & Moss, 2012)

[16] Seed funding = počáteční investice na rozjezd podniku

2 Crowdfunding

V předchozí kapitole jsem jen letmo zmínili, že existuje zdroj financování s názvem crowdfunding, ale již jsme se mu dále nevěnovali. Vzhledem k zaměření práce jsme se namísto toho rozhodli mu věnovat tuto kapitolu, která nám umožní se na téma podívat o něco více do hloubky.

Podobně jako peer-to-peer půjčování je crowdfunding decentralizovaným procesem na financování podniku a podmnožinou takzvaného crowdsourcingu, což je fenomén využití masy lidí k nějakému úkonu.

2.1 Úvod do crowdsourcingu

Doan, Ramakrishnan, & Halevy, (2011) definují crowdsourcingový systém, jako libovolný systém, který využívá davu lidí pomoci vyřešit problém autorovy systému, a zároveň řeší následující 4 teze.

- Jak nabrat a udržet si uživatele?
- Jak může být uživatel přínosný?
- Jak skombinovat přínos jednotlivých uživatelů k vyřešení problému?
- Jak ocenit uživatele a jejich příspěvek?

Je nutné podotknout, že autoři označují uživateli členy davu, nikoli koncového beneficienta crowdsourcingové aktivity (Doan, Ramakrishnan, & Halevy, 2011). Dalším nutným upřesněním je chápání davu. Nemusí se jednat o organizovanou skupinu lidí, která je standardně využívána v podniku či jiných formálních celcích. V kontextu crowdsourcingu je davem jakýkoli celek, který se podílí na řešení problému – může to být management podniku, skupina kolegů nebo neuspořádaná masa lidí zodpovídající dotazy. (Surowiecky, 2004), (Prošek, 2015), (Prpic, Shukla, Kietzmann, & McRathy, 2015), (Chiu, Liang, & Truban, 2014). V neposlední řadě je potřeba si uvědomit, že dav nemusí být jen explicitní (přímo naverbován na řešení problému) ale může být i implicitní (neuvědomuje si, že problém pomáhá řešit).

Vzhledem k tomu, že výše jsme definovali a doplňovali crowdfundingový systém, tak můžeme vyvodit definici crowdfundingu jako takového.

„Libovolná kolaborativní činnost, která vede k řešení specifického problému [za pomoci většího množství lidí, zpravidla přes internet]“

Dodatek definice v “ [*za pomoci většího množství lidí, zpravidla přes internet*]” vychází z citované literatury jen přeneseně, ale především se opírá o využití termínu v přirozeném jazyce. (Dictionaries, 2019).

Jeff Howe, všeobecně považovaný jako autor termínu, nabízí alternativní definici, která je vhodnější pro potřeby této práce.

„Crowdsourcing is the act of taking a job traditionally performed by a designated agent (usually an employee) and outsourcing it to an undefined, generally large group of people in the form of an open call (Howe, 2019).*”*[17]

[17] Outsourcing úkonu tradičně prováděné designovaným agentem (zpravidla zaměstnancem) na nespecifikovanou, obecně velkou, skupinu lidí ve formě otevřené nabídky.

Nicméně, je potřeba poukázat, že Howe nezmiňuje internet, který představuje klíčovou složku, ve své definici. Crowdsourcingové aktivity jsou zpravidla zprostředkovány přes specialisovanou online platformu, kde se potkává nabídka s poptávkou.

Jedním z nejznámějších příkladů crowdsourcingu je Amazon Mechanical Turk (MT)[18], který je online platformou pro decentralizovanou pracovní sílu. MT umožňuje podnikům zadávat na platformu úkoly, které poté účastníci na platformě (dav) vykonávají za úplatu. Nejedná se o komplexní úkoly, ale převážně o velice jednoduché dílčí úkony, jako je přepisování slov mezi Americkou a Britskou angličtinou, kde může být platba až 0.01 dolaru za úkon. (Makonnen & Rogers, 2014)

Obrázek 8 Struktura Amazon Mechanical Turk[19] *Zdroj: https://www.mturk.com/*

Krom vykonávání práce lze například crwodsourcovat i akt prognózování budoucnosti. Příkladem je francouzský start-up Predicti, který se zaměřoval na předpovídání světových událostí. Jejich systém operoval jako burza s fiktivní virtuální měnou, kde došlo k emisi digitálních cenin s hodnotou ekvivalentní předpokládané pravděpodobnosti nějakého jevu. Například, kandidát má šanci vyhrát volby 43 %, takže jedna volební akcie má hodnotu 43 jednotek. Účastník může následně přeprodávat akcie za cenu buď vyšší nebo nižší, se snahou maximalizovat zisk v závislosti na výsledku jevu. Poté co skončí volby, tak budou akcie převedeny na Predicti měnu, tzn., že pokud kandidát A vyhraje a účastník nakoupil akcie za míně než 43, tak generuje zisk. Burzovní gamifikace platformy je nástroj na zapojení davu, a predikce vznikají na základě chování celého ekosystému, kde reálná cena >43 napovídá, že prognóza davu na vítězství politika mu přikládá vetší šanci než basální pravděpodobnost. Velikost delty poté lze kvantifikovat na výslednou prognózu systému. (Lebraty & Lobre-Lebraty, 2013)

Jak i proč systém funguje v prvním případě je zcela zjevné, jedná se o klasickou směnu práce za peníze. Druhý systém funguje díky kombinaci faktorů – intristická motivace účastníků, kdy jsou lidé motivovaní snahou být v něčem dobří, případně se jedná o činnost, která zapadá do jejich sebe-obrazu (např. hráči) a počínání má tendenci být konzistentní se sebeobrazem (Weinschenk, 2013). Pro zadavatele prognostické úlohy to funguje, jelikož agregace individuálních prognóz odbourává nedostatky odhadu jednotlivce a motivace penězi, i když jen virtuálními, podporuje snahu účastníků maximalizovat jejich zisk pomocí co nejpřesnějších prognóz (Lebraty & Lobre-Lebraty, 2013).

[18] https://www.mturk.com/
[19] Struktura MT je konceptuálně stejná jako ostatní crowdsourcingové platformy

2.2 Úvod do crowdfundingu

Crowdfunding je variantou crowdsourcingu, kde úkolem je financování podniku či projektu, a dav nahrazuje tradiční nástroje financování představené v kapitole 1.

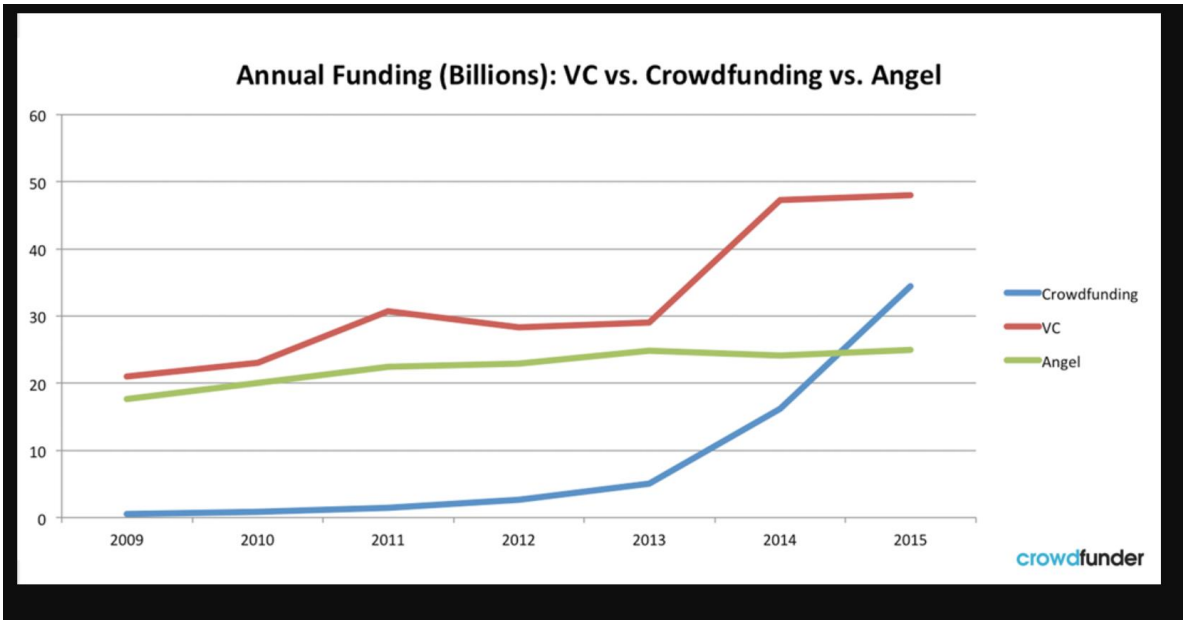

Obrázek 9 Růst crwodfundingu, angel investmentu a venture captial investmentu

zdroj: (Barnett, 2015)

Kde se dá říct, že na koncepční úrovni je institucionální investor nahrazen davem, tak to samé se děje i na tržní úrovni. Data z roku 2015 ukazují, že pomocí crowdfundingu se celosvětově již investuje více prostředků, než kolik investují business Angels, a byl na cestě k překročení i investiční kapacitě venture fondů. Angels v roce 2014 investovali 20 miliard dolarů celosvětově, VC 45, což je částka, kterou by crowdfunding dohnal v roce 2016 pokud by pokračoval jeho trend růstu. Nicméně, je nutné podotknout, že část Angels a VC aktivity se přesouvá na crowdfundingové platformy (více viz. dále), takže reálně není jejich vytěsňování tak zásadní, jak by se na první pohled mohlo zdát. (Barnett, 2015)

Jedním z vysvětlení, proč dochází k tak zásadnímu posunu ve prospěch financování je generační obměna ve společnosti, kde mileniálové vykazují signifikantně odlišné chování vzhledem k investicím do akcií atp., než předchozí generace. Jak ukazují **Obrázek 10** a **oObrázek 11**, tak jich méně investuje do akcií, ale více má tendence investovat crowdfundingem ve srovnání se staršími demografiemi. (Terry, Schwartz, & Sun, 2015)

Exhibit 15: Millennials are less invested in stocks…
Approximate overall asset allocation; other includes alternative investments, real estate, commodities, etc.

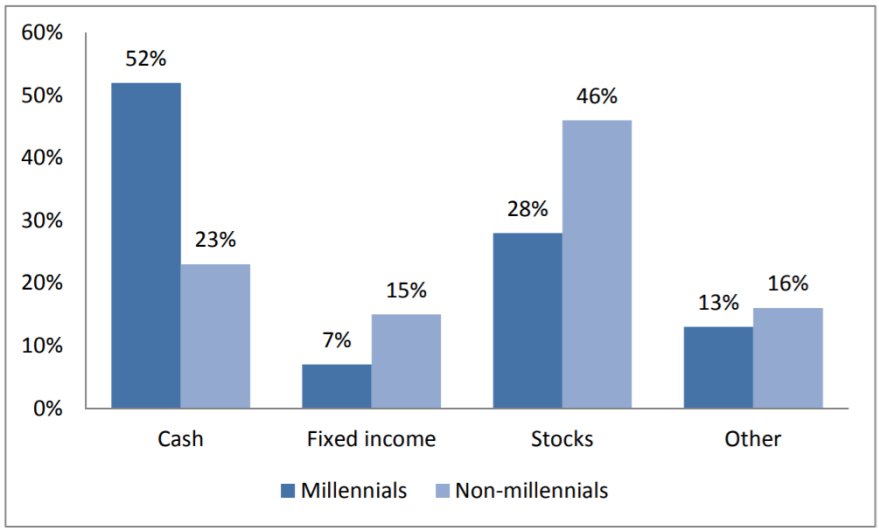

Source: Gallup

Obrázek 10 Demografické dělení kapitálové struktury jednotlivců

zdroj: (Terry, Schwartz, & Sun, 2015)

Exhibit 16: …And more likely to participate in crowdfunding
% of respondents who have given or are likely to give via crowdfunding in the next 12 months

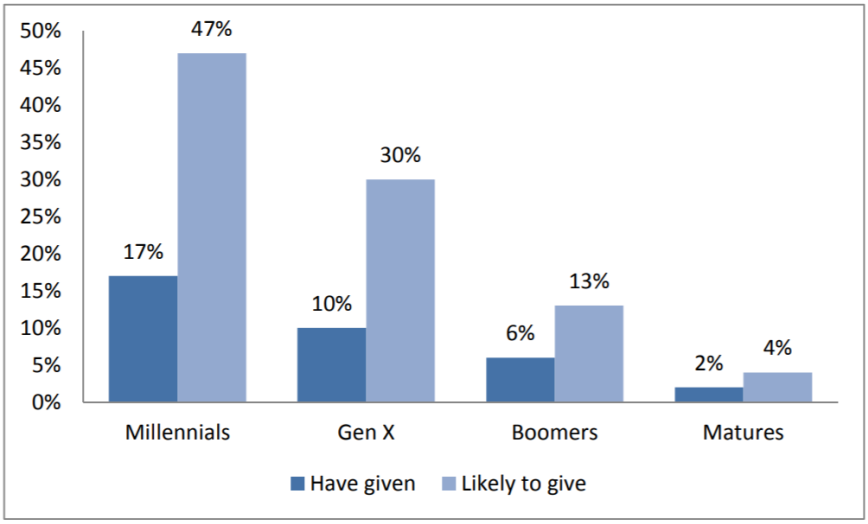

Source: Blackbaud

Obrázek 11 Demografické rozdělení tendencí invetovat pomocí crowdfundingu

zdroj: (Terry, Schwartz, & Sun, 2015)

Otázkou dále je, jestli se jedná o důsledek nebo příčinu, ale crowdfundingu nahrává i demografická distribuce napříč sociálními sítěmi, a aktivita na nich je jedním z klíčových kroků úspěšné crowdfundingové kampaně. Facebook má 2 miliardy unikátních uživatelů měsíčně (2x tolik co druhý YouTube) a souběžně s tím jsou mileniálové právě ti, kdo nejvíce sdílí obsah na této platformě (společně s Instagramem, přidávající jejich dosahu další 800 milionů uživatelů měsíčně (Spreadfast, 2019).

Krom nesporné výhody, kterou je postupné navyšování agregátního kapitálu přes crowdfunding, je dalším benefitem i jistá forma pre-validace vašeho obchodního záměru. Obvaziště, pokud se snažíte získat funding pomocí reward-based[20] platformy, tak máte přímou zpětnou vazbu na marketabilitu vašeho produktu. Jistým způsobem se jedná o value-added investment, kde ale na místo obchodní expertízy budujete vaši zákaznickou základnu, a komunitu kolem vašeho brandu ještě před tím, než váš produkt vznikne. (Mollick, 2016)

Na druhou stranu, příkon finančních prostředků neznamená nutně, že každý projekt bude úspěšně zafinancován. Míra úspěšnosti na 2. celosvětově největší platformě je jen 9 % (Krowdster, 2015).

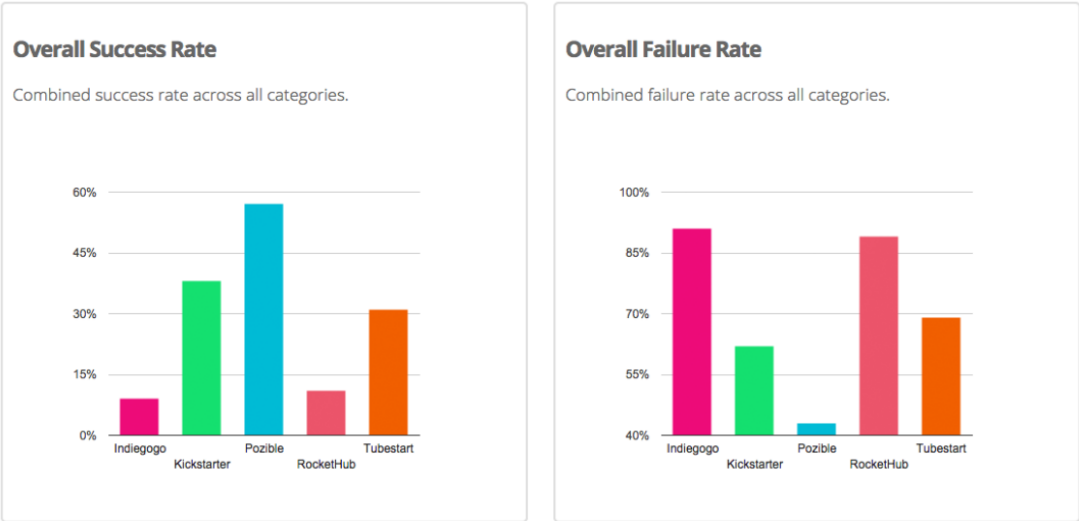

Obrázek 12 Proporcionální zobrazení úspěšných a nespěšných projektů dle platformy

zdroj: (Krowdster, 2015)

Dalším faktorem, který je nutno brát v potaz je pozdní doručování produktů/projektů financovaných tímto způsobem. Jen cca 25 % doručí koncovému zákazníkovy včas. Lze i poukázat na fakt, že podvodné kampaně, které by se snažili vybrat peníze, ale neměli za cíl doručit zboží jsou spíše výjimka, a většina projektů eventuálně doručí (Mollick, 2014). Tzn., že zpoždění má praktické dopady na zákazníky/investory jen částečně, a vzhledem k frekventovanosti zpoždění, lze předpokládat, že s ním částečně počítají. NA druhou stranu, jelikož tento proces probíhá zpravidla ve veřejné doméně – z podstaty crowdfundingu musí být data viditelná širokou veřejností – tak je riziko, že zpoždění umožní existující firmě okopírovat projekt a předběhnou začínajícího podnikatele na trh.

2.3 Varianty crowdfundingu

[20] Viz **kapitola 2.3.1**

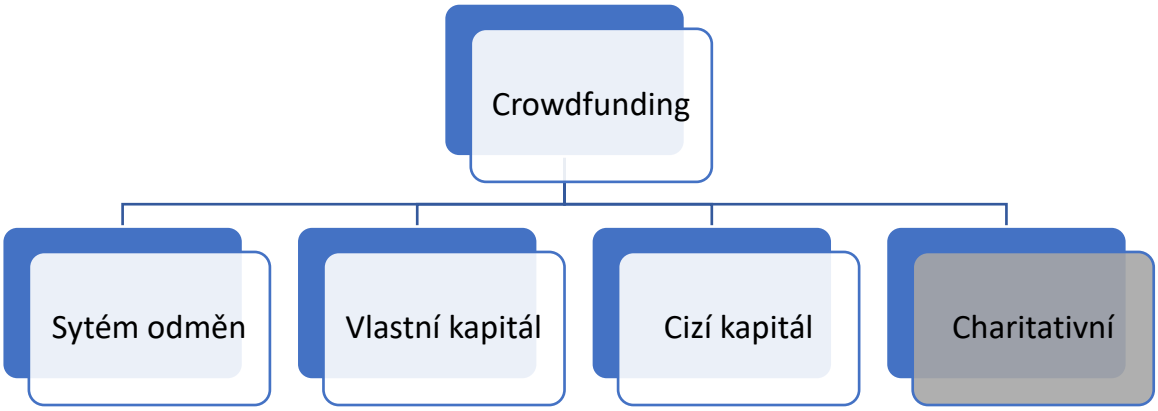

Obrázek 13 Dílčí dělení crowdfundingu

zpracováno podle: (Freedman & Nutting, 2015)

Obrázek 13 představuje čtyři základní varianty crowdfundingu, vzhledem k investiční povaze.

2.3.1 Odměnový crowdfunding

Crowdfunding založený na odměnách se asi nejvíce liší od dosud probíraných postupů financování. Nejedná se totiž o kapitálový vztah, jak popsáno v **kapitole 1**. Vlastní podniku, který se snaží vybrat peníze tímto způsobem nepostupuje podíl na vlastnictví podniku ani negeneruje dluh. Investoři (dav), i když v tomto případě je vhodnější použít termín zákazník, dostanou výměnou za poskytnuté finance nefinanční odměnu. Příkladem odměn je příslib produktu, poté co začne produkce, poděkování, možnost navrhnout změnu na produktu, osobní setkání se zakladateli podniku, a jiné. Z velké části se dá říct, že se jedná o financování pomocí předprodeje zboží nebo zálohy za zboží, kde platba přechází poskytnutí produktu/služby, ale je očekávána. Zde je také nejpatrnější výhoda, jak popsána (Mollick, 2016) vzhledem k přímé vazby na zákaznickou základnu.

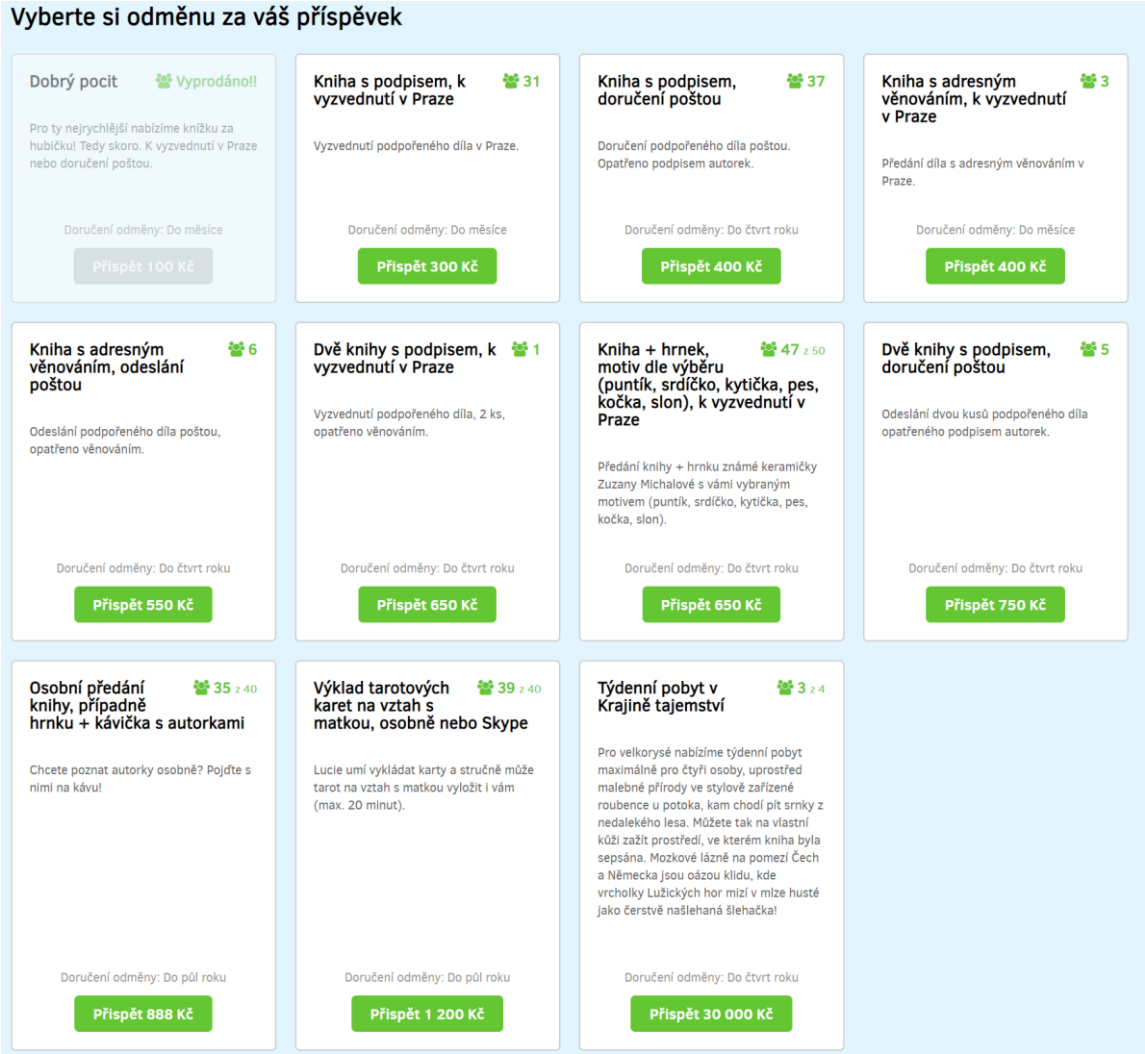

Obrázek 14 Možná struktura odměn crowdfundingové kampaně

zdroj: (Jandová & Kaplanová, 2018)

Obrázek 14 zobrazuje konkrétní sadu odměn pro právě běžící kampaň – snaží se financovat vydání vlastní knihy. Je patrné, že krom „předprodeje“ je možné získat za finanční prostředky službu od autora (výklad z karet), která není přímo součástí projektu, nebo spolufinancovat projekt darem („dobrý pocit“)

Odměnový crowdfunding je zdaleka nejrozšířenější metoda, na čemž má zásadní podíl legislativní regulace ostatních forem. Zde neprobíhá obchod s kapitálem ani dluhem, tudíž nebylo potřeba vytvořit novou legislativu která by tento druh zastřešovala. (Belleflamme, Lambert, & Schwienbacher,, 2014)

2.3.1.1 Platformy odměnového crowdfundingu

Stejně jako tomu bylo u crowdsourcingu, existuje široká řada online platforem, které podporují tento typ financování. Crowdfundingconferenceseminar.com eviduje přes 500 aktivních portálů, a dovolíme se je rozdělit do dvou skupin – univerzální a účelové.[21] Uvedeme nicméně jen pár překladů, nikoli souhrnný výčet vzhledem k souhrnnému množství.

Obchodní model universálních platforem je zpravidla postaven na provizi z vybraných prostředků (3 až 5 %), kdežto specializované hojně uzpůsobují svůj zdroj příjmů jejich nice.

Universální platformy – minimální nebo žádná specializace obsahu

- **Kickstarter** (všechno nebo nic)

Kickstarter je největší platforma svého druhu, založena v roce 2009 a k lednu 2014 se přes něj vybralo 960 milionů dolarů na úspěšné projekty. Jedná se o platformu s modelem „všechno-nebo-nic," a to znamená, že finance budou projektu (podniku) poskytnuty jen pokud se mu podaří vybrat cílovou částku. Pokud ne, taka budou všechny peníze vráceny investorům.

Jednou z unikátních vlastností Kickstarteru je přístup k tomu, co přes něj lze financovat, a každý projekt podstupuje schvalování z jejich strany. Výhradně se zaměřuje na projekty, které jsou na svém konci schopny vytvořit konkrétní nový produkt. Nejedná se tak o nástroj, přes který bz šlo financovat vývoj služby (nebo charitativní aktivitu)[22] (Rich, 2014)

- **Indiegogo** (flexibilní)

Indiegogo je celosvětově druhou největší platformou odměnového crowdfundingu. Založena roku 2008 za účelem financování nezávislých filmů, ale v roce 2009 se změnila na universální platformu. Na rozdíl od Kickstarteru operuje s flexibilním finančním modelem – všechny vybrané finance jsou předány týmu za projektem, i když nesplní svůj cíl. Autoři nicméně mohou přistoupit na opačný model z vlastní iniciativy.

Obsahová politika Indiegogo je také volnější než Kickstarteru, kde je podporován libovolný projekt a neprobíhá žádné dopředné schvalování. (Rich, 2014)

- **HitHit (všechno nebo nic)**

HitHit je největším českým odměnovým portálem, kde se mezi jeho vznikem v roce 2012 a rokem 2104 investovalo 24 milionů. Sleduje stejný přístup k financování i obsahu jako Kickstarter. Za zmínku ale stojí omezení kampaní, kde může jedna běžet maximálně 45 dní. (HitHit, 2019)**,** (MarketingSalesMedia, 2015)

Specialisované platformy – obsahově cílí na konkrétní mix investorů a projektů

- **Dragon Innovation (všechno nebo nic)**

Platforma Dragon Innovation operuje pod střechou stejnojmenné poradenské firmy, se zaměřením na technologie. Jako taková je platforma otevřena výhradně vynálezcům na poli hardwaru.

Dragon Innvoation se vymezuje především přidanou hodnotou pro podnikatele. Korm akumulace finančních prostředků pomocí davu, také poskytují in-house poradenství co se týká designu,

---

[21] Napříč spektrem, nejen odměnových. Na druhou stranu, stránka prozatím nezahrnuje tuzemské portály. Lze tedy předpokládat vyšší množství v současnosti fungujících platforem.

[22] Charitativní aktivity mají dedikované platformy, ale většina odměnových umožňuje tuto aktivitu také.

výroby a marketingu každému z úspěšných produktů. Mají k tomu značně individualizovaný přístup, takže na stránkách nezveřejňují více než 40 projektů za měsíc, a každý prochází poměrně přísným screeningem. Výhodou selektivity platformy je velmi vysoká úspěšnost projektů, jak z hlediska akumulace kapitálu, tak produkce. (Rich, 2014)

- **<u>Fundable</u> (všechno nebo nic)**

Fundable se zaměřuje výhradně na malé a střední podniky, ať už v případě investic do celé firmy nebo konkrétního komerčního produktu. Vzhledem k zaměření nabízí možnosti zakládat projekty jak na odměnovém principu, tak i investiční, kde se autoři snaží navýšit vlastní kapitál výměnou za podíl ve firmě.

Z odměnového hlediska se Fundable podobá více Kickstarteru než Dragon Innovation, pokud pomineme obsahové zaměření. Hlavním rozdílem je, že namísto provize účtují fixní měsíční poplatek 179 dolarů. (Rich, 2014)

2.3.2 Investiční crowdfunding[23]

Investiční crowdfunding, stejně jako Venture kapitál a Angels, umožňuje investorům směnit finanční prostředky za podíl na vlastnictví firmy.

Zásadním rozdílem oproti jmenovaným investorům je způsob, jakým probíhá získávání prostředků, a to přes specializovanou platformu. Platí to pro případ, kdy je investorem široká veřejnost i když jako dav chápeme jen skupinu akreditovaných investorů. Obzvláště v případě business angels je investiční crowdfunding radikální evolucí z pohledu efektivity. Na místo spoléhání se na reference a osobní kontakty může angel identifikovat množství preferovaných projektů na pár kliknutí klávesnice. Podobně je tomu i z druhé strany, kde podnikatel nepotřebuje pracně dělat individuální prezentaci každému z investorů, ale má uniformní marketingovou strategii. (Makonnen & Rogers, 2014). Ve druhém případě nicméně nesmí podnikatel podcenit menší dávky individualizované komunikace, vzhledem k sociální povaze crowdfundingu (Mollick, 2014). Z pohledu podnikatele je také nevýhodou rozmělňování investic s přidanou hodnotou. Čím větší dosah budou investoři mít, tím menší individuální pozornosti se bude každý z podniků moc těšit.

Na místě je také doporučení důsledného studia legislativy. Vzhledem k tomu, že se jedná o finanční transakce tak je investiční crowdfunding podroben poměrně složité právní úpravě, který se v ČR a zahraničí. Například v USA jsou některé úkony omezeny jen na akreditované investory, kdežto v Čechách toto omezení neplatí. (Makonnen & Rogers, 2014), (Bachtík, 2018). Pro další podrobnosti doporučujeme zkonzultovat dostupnou literaturu. Právní úpravě v této práci není věnován delší prostor.

2.3.2.1 Samotné fungování investičního

Investiční crowdfunding z pohledu investora i podnikatele takřka stejně jako u odměnového crowdfundingu. (**Obrázek 15** a **Obrázek 16**[24])

[23] Equity crowdfunding

[24] Převzato ze stánek první tuzemské platformy, ale proces je podobný i u ostatních zprostředkovatelů

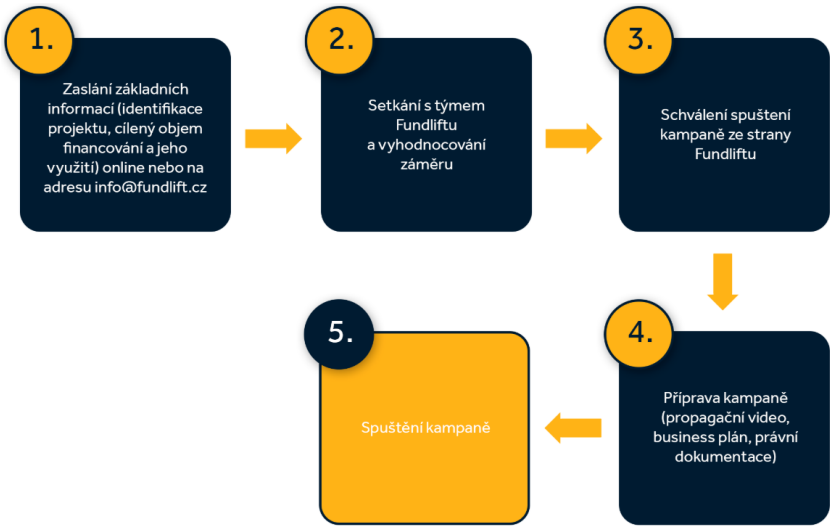

Obrázek 15 Proces investičního crowdfundingu z pohledu podnikatele [na platformě Fundlift]

Zdroj: (Fundlift, 2019)

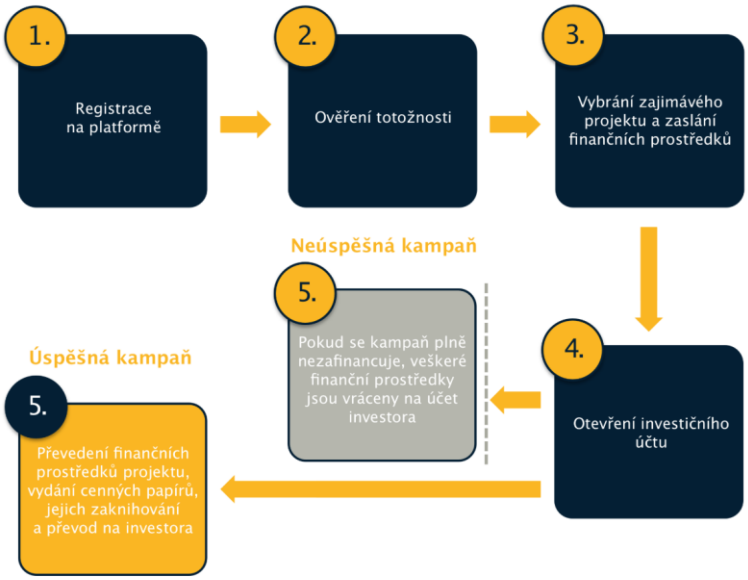

Obrázek 16 Proces investičního crowdfundingu z pohledu investora [na platformě Fundlift]

Zdroj: (Fundlift, 2019)[25]

[25] Distribuce cenných papírů probíhá pomocí akreditovaného obchodníka, ne platformy samotné (Fundlift, 2019)

2.3.2.2 Platformy investičního crowdfundingu

- **AngelList**

Založen roku 2010, AngelList je nejstarší z crowdfundingových platforem. V roce 2014 zprostředkovali 104 milionů dolarů a jejich prostřednictvím vzniklo 243 nových startupů ten samý rok. Jak již název napovídá, tak se AngelList zabývá propojováním nových firem a business Angels, především prostřednictvím syndikace. Tento proces spočívá v klasickém propojení jednotlivého investora (Angel) s podnikem hledajícím kapitál. Investor následně může přizvat další investory, aby vytvořili syndikát neboli skupinu investorů. Sdružování investorů slouží k diversifikaci jejich rizika a zároveň
poskytuje víc kapitálu SME podnikům na platformě.

Krom investic zprostředkovává AngeList i Recruitment (AngelList, 2019), (Crunchbase, 2019)

- **Fundable**

Souhrnně popsán v kapitole **2.3.1.1**

- **Fundluift**

Česká platforma založena roku 2015, a v současnosti největší na tuzemském trhu.[26] Od svého vzniku zprostředkoval investice přesahující výši 250 milionů korun napříč 43 projektům. Minimální hodnota investice začíná již na 5000 korun, a průměrná investice představuje 33. (Bdrich, 2018)

2.3.3 Úvěrový crowdfunding

Jedná se o peer-to-peer půjčování, jak popsáno v **kapitole 1.2.3.7**. Literatura nicméně mnohdy specifikuje jen tento způsob financování mimo crowdfunding, Například. (Makonnen & Rogers, 2014) jelikož ho považují za více konvenční. Z tohoto důvodu jsme ho i my zahrnuli mezi ostatní nástroje v předcházející části této práce.

2.3.4 Charitativní crowdfunding

Charitativní crowdfunding je zde zmíněn jen pro úplnost, jelikož se nejedná nástroj financování ziskové aktivity či generování obratu. Na místo toho se soustředí ryze na charitativní účely, kde se jedná o elektronickou sbírku na charitativní účel. Z tohoto pohledu je také nejméně inovativní, jelikož se charity věnovali této činnosti dávno před tím, než dostala své označení. (Freedman & Nutting, 2015)

[26] Z pohledu investičního i dalších druhů crowdfundingu.

3 Forecasting

Forecasting, neboli prognózování, představuje druhý obsahový pilíř teoretické části této práce, a současně jeden ze stěžejních, nejen, podnikových procesů. Naneštěstí pro obchodní organizace je budoucnost stochastické povahy, a nikoli deterministický, a tudíž nelze přesně říct co se stane. Je však možné odhadnout více či méně pravděpodobný stav budoucích věcí, dle kterého by se mělo následně odvíjet podnikové rozhodování. Přesně tento odhad he podstatou forecastingu.
Sanders, (2016) definuje prognózování jako proces předpovídání budoucnosti. Kdykoli kdy uděláme předpověď nebo odhad budoucího jevu, tak prognózujeme. I když o této činnosti zpravidla neuvažujeme tak formálně, provádíme ji takřka neustále v každodenním životě. Pro ilustraci, odpověď na libovolnou z následujících otázek je aktem prognózování

- Jak dlouho mi potrvá cesta do práce?
- Kdo vyhraje volby?
- Získá Česko medaili v šermu na nadcházejících olympijských hrách?
- Bude index S&P 500 rúst?
- Jaký bude roční obrat mého podniku?
- Přežijí květiny zimu?
- Nespálím večeři?

V podnikové sféře možná klademe jiné otázky, se zaměřením na prodeje, vývoj trhu, konkurenci, atp., ale fundamentálně se zajímáme o jedno a totéž – obraz budoucnosti.

Než pokročíme dále při popisu forecastingu, je potřeba identifikovat další 2 podnikové procesy, s prognózováním úzce spjaté (Sanders, 2016).

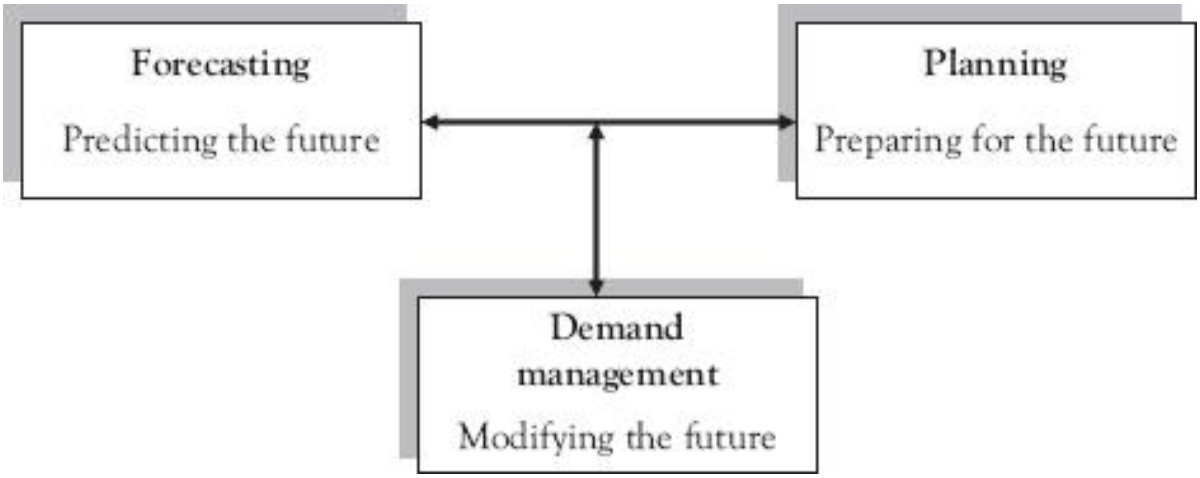

Obrázek 17 Plánování, Prognózování a řízení poptávky

zdroj: (Sanders, 2016)

- **Plánování** se zabývá přípravou na budoucnost, respektive tím, jaký by měla budoucnost vypadat. (Armstrong J. S., 1985)
- **Řízení poptávky** je poté zaměřeno na ovlivnění budoucnosti do kýženého stavu. (Sanders, 2016)

Všechny tři zmiňované procesí mají jistý vzájemný přesah, ale zjednodušeně řečeno musí organizace nejdříve provést odhad budoucího vývoje (forecast), následně se na tento vývoj připravit

(plán) a pokud jí to zdroje dovolí, tak se pokusit tento vývoj ovlivnit ve svůj prospěch (řízení poptávky), např pomocí marketingu či jiných aktivit.

Nicméně, plánování ani řízení poptávky není předmětem této práce, a pro další studium je k dispozici velké množství literatury na tyto témat. Tím však nechceme říci, že tyto aktivity jsou méně důležité než prognózování. Přínos dlouhodobého plánování byl znám již v 80. letech minulého století. (Armstrong J. S., 1985)

3.1 Prognózování v praxi

První, co je potřeba zmínit, že přesně předpovědět budoucnost je nemožné, a libovolný subjekt který využívá prognózy k podnikovému (či jinému) rozhodování musí toto vzít v potaz. Bohužel, management podniku je často neochotný přijímat tyto závěry, a radši vezme za vděk prognózám předloženým s větší mírou jisty. Toto může mít nicméně zásadní negativní dopady – např. doporučení profesionálních brokerů na burze jsou mondy nejen srovnatelné, ale dokonce horší než zcela náhodné rozhodování. I když existují empirické důkazy o zde zmíněném, tak je tento fakt velmi často mezi akademiky a podnikateli odmítán a nahrazován „ilusí kontroly," kde si aktéři chtějí myslet, že jsou přesné prognózy možné. (Makridakis & Taleb, 2009)

Bylo by nicméně nesprávné říci, že prognózování není přínosné. Jen je potřeba si uvědomit některá omezení. Stejně jako tomu bylo v **kapitole 1 nahoře1**, když jsme hovořili o financování, se zde pokusíme poskytnou shrnutí možností a poznatků disciplíny.

Prostor bude věnován jak forecastingu založeném na lidském úsudku, tak i více algoritmickým přístupům. Obecně doposud nepanuje shoda na významu role člověka oproti stroji. V některých doménách počítačové a statistické modely snadno předčí lidské posouzení, v jiných případech je tomu právě naopak. V neposlední řadě je také nutné vzít v potaz, že nejlepším přístupem je většinou předstup hybridní, kdy kombinujeme člověka a statistický model k dosažení výsledku (Chase, 2013).

3.2 Vypořádání se s nejistotou v prognózách

Jak bylo v úvodu ukázáno, buducnost je nejistá a není možné podávat prognózy se 100 % přesností. Nicméně, to neznamená, že nelze uživatelům usnadnit práci s prognózami.

(Sglavo, Tashman, & Gilliand, 2016) nabízí několik postupů, jak prezentovat data, a některé z nich umožňují zahrnout míru nejistoty.

3.2.1 Bodový forecast

Nejčastěji používaná forma prezentace prognóz. Jedná se o forecast, který každé odhadované veličině přiřadí právě jednu hodnotu. Např. v roce 2021 se odhaduje velikost farmakologického průmyslu na 1170 miliard dolarů, nebo zítra bude 17 stupňů s přeháňkami[27]. Výhodou této formy je její snadný uchopitelnost uživateli a akceptovatelnost, vzhledem k iluzi kontroly diskutované výše. Hlavním nedostatkem je, že nijak nezohledňuje míru nejistoty (rizika). Zjednodušený příklad je, když odhadnu že na šestistěnné hrací kostce padne číslo 4. Opomeneme-li, že všichni si dokáží představit hrací kostku, tak by uživatel prognózy předpokládal, že mám důvod pro tento konkrétní odhad. Forecast ale již nepodává informaci o tom, že lze očekávat jeho přesnost jen v 17 % případů.

[27] Ilustrativní tvrzení, která splňují představu prognózování. Nejedná se o de facto prognózy, které by byly přejaty z dalších zdrojů.

3.2.2 Predikční intervaly

Intervaly jsou jednoduchým zobrazením nejistoty, kde namísto bodového forecast poskytne prognostik numerické rozmezí. Např., že zítra bude mezi 12 a 20 stupni celsia. Čím širší interval, tím větší míra nejistoty je spjata s prognózou.

3.2.3 Vějířové grafy

Vějířový graf je zobrazení prognózy, které krom bodového forecastu zahrnuje i několik predikčních intervalů. **Obrázek 18** zobrazuje takový případ, kde tmavě modrý region reprezentuje hodnoty, kterých zkoumaný jev nabyde s 50% jistotou, tmavě zelený s jistotou 75 % a světle zelený 95%.[28]

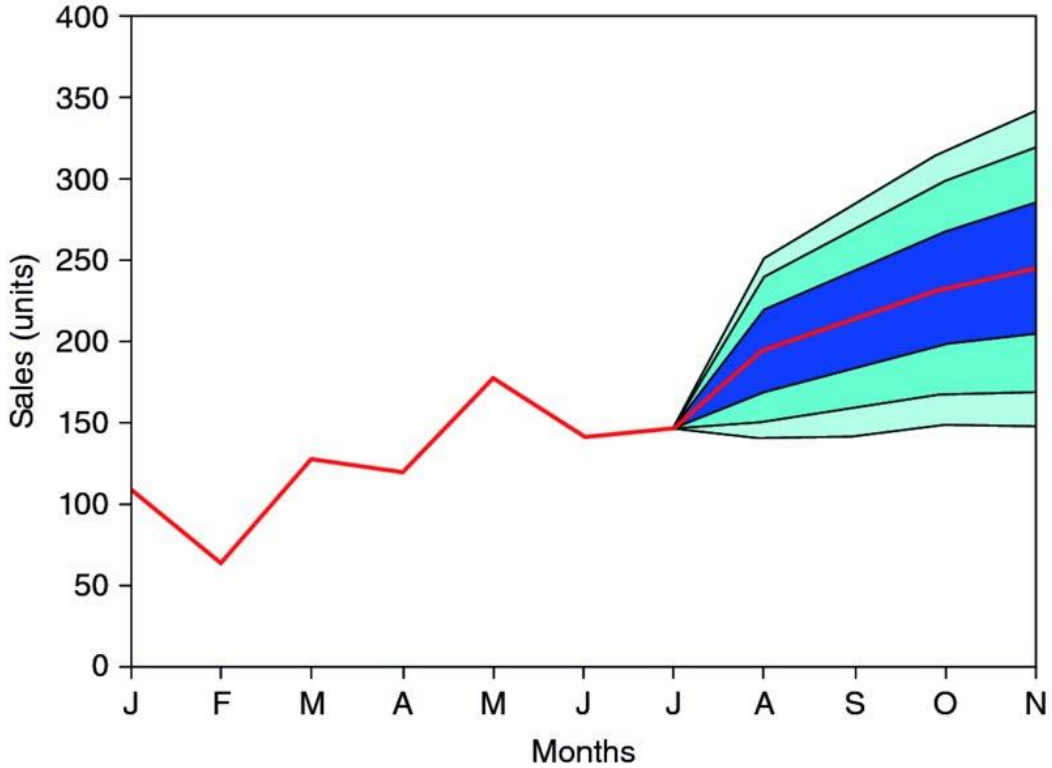

Obrázek 18 Vějířový graf

zdroj: (Sglavo, Tashman, & Gilliand, 2016)

3.2.4 Hustoty pravděpodobností

Hustota pravděpodobností je histogram odhadů, ze kterého lze snadno vyčíst jaký jev, respektive stav jevu, nastane s největší pravděpodobností. Jelikož se ale jedná o kompletní zobrazení rozdělení pravděpodobnosti tak je možné i vyčíst pravděpodobnost extrémních výsledků.

Histogram na **Obrázek 19** bývá také často doplněn o graf kumulativní pravděpodobnosti (**Obrázek 20**), který zobrazuje, s jakou pravděpodobností nastane cílová či vyšší hodnota zkoumaného jevu. První ze zde využitých příkladů říká, že pravděpodobnost prodeje právě 550 kusů je 12 %, ale už přímo neukazuje jaká je pravděpodobnost prodeje 12 či víc kusů. Druhý z grafů ukazuje, že zkoumaný jev nabyde hodnoty 0.05 nebo vyšší s pravděpodobností 72.5 %.

---

[28] Regiony se překrývají, takže vnější intervaly zahrnují i pravděpodobnost výsledků v intervalech vnitřních.

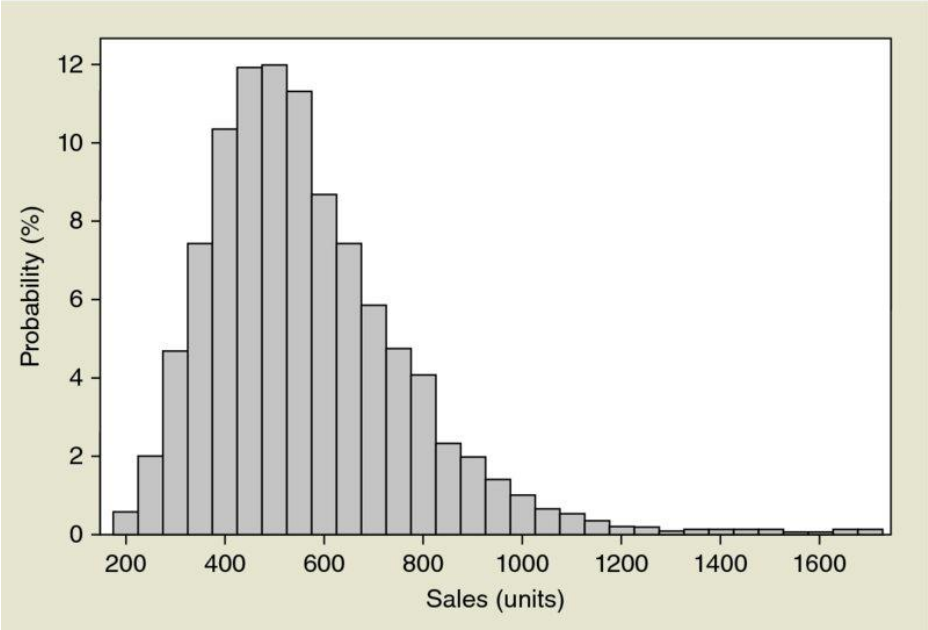

Obrázek 19 Rozdělení hustoty pravděpodobností

Zdro: (Sglavo, Tashman, & Gilliand, 2016)

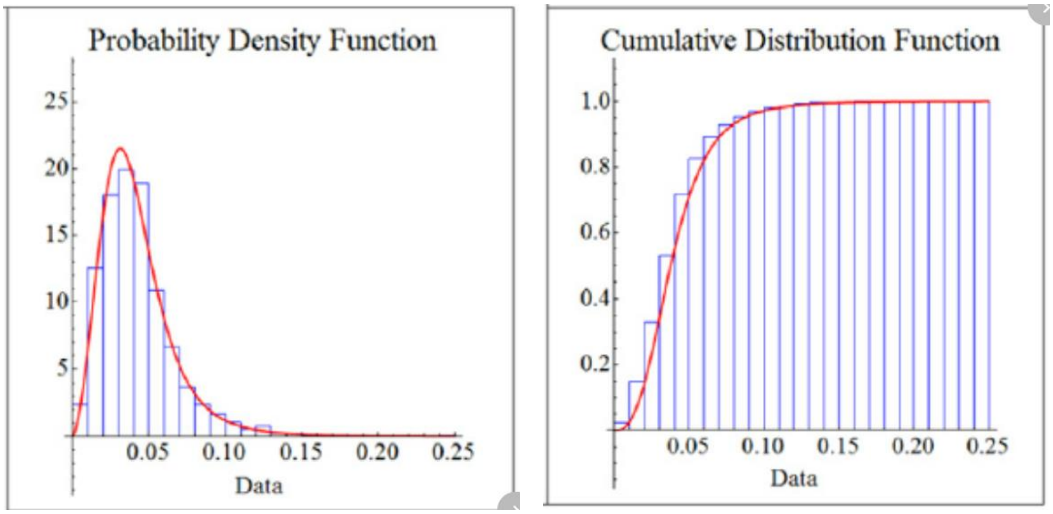

Obrázek 20 Rozdělení hustoty pravděpodobnosti a kumulativní hustota pravděpodobnosti

Zdroj: (Murari, a další, 2014)

Pravděpodobnostní zobrazení se potýkají s vlastními omezeními. Hlavními problémy je dezinterpretace výsledků, a také možné odmítnutí ze strany konzumenta prognózy. Interval je přijímán jen v omezené šíři, předtím, než je prognóza zavrhnuta jako bezpředmětná. Prognostik, který předestře, že se v nacházejícím roce prodá 50 až 900 kusů produktu, s 90% jistotou bude vypoklonkován, s tím, že neposkytuje přidanou hodnotu. Management upřednostňuje specifičtější data, i za cenu nižší preciznosti. (Goodwin, Gönül, & Önkal, 2013), (Du, Budescu, Majorie, & Omer, 2011)

3.3 Uplatnění lidské expertizy

Intuitivně lze očekávat, že lidé, kteří se dlouhodobě pohybují v oboru, a mají hluboké znalosti své domény budou lepší v sestavování prognóz než jedinci, které bychom za experty nepovažovali. V praxi není odpověď zdaleka tak černo-bílá, a akademický výzkum dospívá k protichůdným výsledkům. (Lawrence, Goodwin, O'Connor, & Önkal, 2006). Portfolio manažeři jsou takřka univerzálně horší prognostici než samotná náhoda, kde akciové indexy znovu a znovu překonávají výkony profesionálních investorů (Surowiecky, 2004), (Makridakis & Taleb, 2009). V klinickém prostředí lze pozorovat podobné trendy, kde počítače překonávají člověka v diagnostice. (Kahneman, 2011). Do jisté míry protichůdné výsledky má výzkum (Chase, 2013) nebo (Seifert & Hadida, 2012), kteří přisuzují oborovým znalostem pozitivní dopady na prognózy.

(Lawrence, Goodwin, O'Connor, & Önkal, 2006) definovali oborovou znalost jako „Jakékoli informace vztažené k prognostickému úkolu, jiné než [samotná] časová řada“. Také dodávají, že oborový specialisté jsou lepší na interpretaci kontextuálních informací než samotné statistické modely.

(Armstrong J. S., 1985) se staví někam na pomezí těchto dvou stanovisek, kde sice uznává přínos expertizy, ale také si myslí, že je relevantní až při větším počtu odhadců.

V důsledku je možné, že predikovatelnsot některých jevů lidskými aktéry je vyšší než jevů jiných. Pokud by tomu tak bylo, tak mají pravdu oba tábory. Finančníci byli již několikrát zmíněni jako experti bez zásadní přidané hodnoty, z pohledu prognózování. Na druhou stranu Seifert & Hadida, {2012) (nejen, že dokázali prediktivní validitu expertizy při předpovídání popularity nových písní experty a lajky, ale i fakt, že její míra je poměrně relevantní. Lidé pohybující se déle v oboru byly přesnější než nováčci, kteří byli přesnější než laici (Seifert & Hadida, 2012).

Jako shrnutí můžeme říct, že tato otázka je stále velmi otevřená a zaslouží si další výzkum. Je tak velmi dobře možné, že prognózování by se mělo ponechat počítačům a těm pracovníkům, kteří se zrovna zabývají zkoumaným jevem. Expertní znalosti by poté bylo možné lépe uplatnit v jiných podnikových činnostech. Je také nutno podotknout, že i když expert nemusí být lepší forecaster než obecně vzdělaný člověk, tak může mít zásadní přímost pro vlastní design a implementaci prognostických postupů.

3.4 Prognostické postupy

V textu jsme se již několikrát zmínili jak člověka, tak algoritmy, jakožto aktéry prognostické praxe. Tato kapitola se porto bude věnovat shrnutí několika základních přístupů k forecastingu.

Nejprve je potřeba vymezit dvě hlavní skupiny – kvalitativní (judgmental) a kvantitativní prognózování.

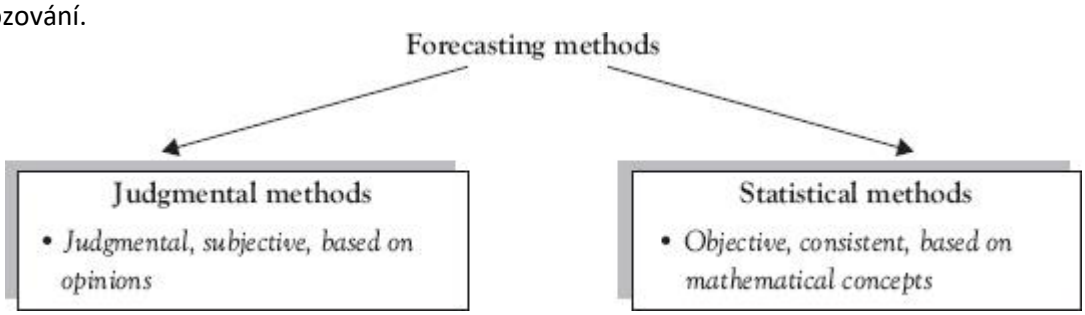

Obrázek 21 Kategorizace prognostických metod

zdroj: (Sanders, 2016)

První ze jmenovaných kategorií je založena na využití lidského úsudku. Druhá kategorie potom stojí ryze na matematických a statistických nástrojích. Krom těchto dvou skupin se požívají ještě smíšené prognózy, které mají komponent jak kvalitativního, tak kvantitativního forecastu, a pár slov věnujeme i nastavování cílů.

3.4.1 Nastavování cílů

Nastavování cílů neboli „target-setting“ je nejrozšířenější prognostičku metodou, i když to vlastně žádná metoda forecastingu není. Společnosti započnou plánovací proces nastavením cíle meziročního růstu, který je následně kaskádováí vrcholným management napříč organizací. Každý stakeholder následně nastaví svůj dílčí cíl, podle toho, co si myslí, že je realistické. Pokud se následně agregátní dílčí cíle neshodují s organizačním, tak vrcholový management buď předepíše navýšení dílčích cílů nebo vytvoří celopodnikovou zátku (prodeje, které by měli pokrýt vzniklou mezeru), v naději, že určitá podniková jednotka překoná vlastní odhad. Tento proces je provázen naprostým minimem kvantitativních metod, obzvlášť když by se výsledky neslučovali s korporátními záměry nebo potřebami (Chase, 2013).

3.4.2 Kvantitativní metody

Kvantitativní metody lze dále rozdělit na dva hlavní proudy, dle metodologie.

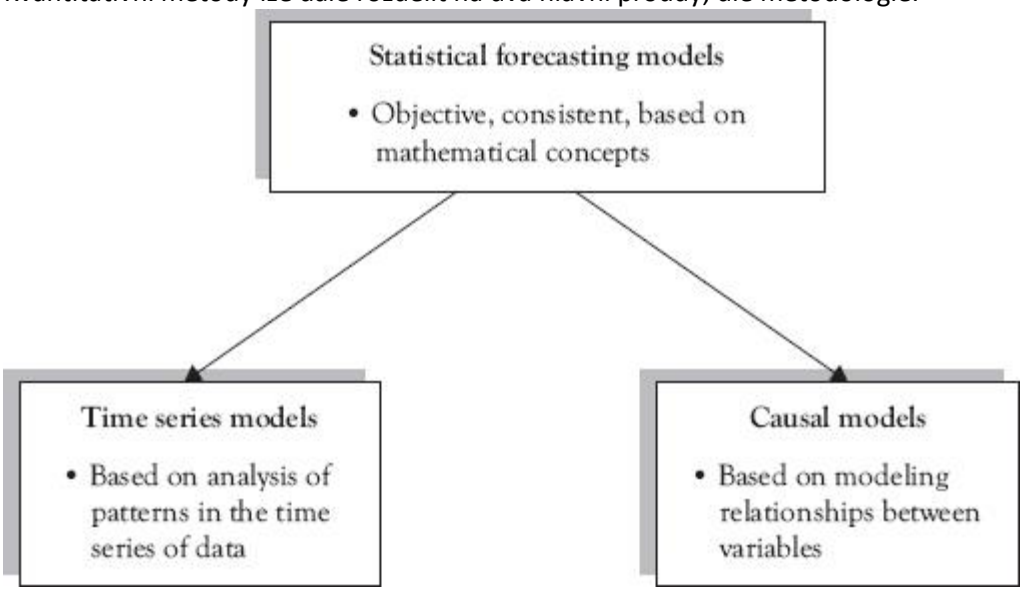

Obrázek 22 Dílčí členění prognostických metod

Zdroj: (Sanders, 2016)

3.4.2.1 Časové řady

Časovou řadou chápeme uspořádání proměnných dle zařazení v čase. Čas nefluktuuje, a postupuje uniformně v jednom směru, od minulosti do budoucnosti. Časový interval se kterým pracujeme si můžeme určit dle vhodnosti aplikace, ale musí se počítat v konzistentních inkrementech.

Metody prognózování časových řad se snaží identifikovat trendy [dat] v čase, přes fixní intervaly, za pomoci identifikace cyklů, sezónnosti a jiných vztahů, ze kterých se pokoušíme vyvodit budoucí vývoj. (Sharma, 2006)

3.4.2.1.1 Klouzavý průměr

Jednou ze základních technik práce s časovými řadami jsou klouzavé průměry. Jedná se o prostý průměr několika po sobě jdoucích hodnot v časové řadě, který se posouvá odstraněním nejstarší hodnoty v časové řadě a přidáním nejnovější. (Molugaram, Shah, Rao, & Davergave, 2017)

Matematicky jsou klouzavé průměry popsány následujícím vztahem:

$$\frac{y_1+y_2+\cdots+y_m}{m} \; ; \; \frac{y_2+y_3+\cdots+y_{m+1}}{m}$$

Kde

- *Yt* je suma hodnoty měřené veličiny v čase t
- *m* je počet hodnot Y, které jsou zohledněny v klouzavém průměru.

Rovnice 1 Klouzavý průměr

Výhodou této metody je odstraňování náhodných výchylek ve zkoumané veličině, jelikož se agregací více hodnot vyhlazují. Nevýhodou je potom náchylnost na extrémní hodnoty. Příkladem je snaha předpovídat lednové prodeje spotřebního zboží na základě klouzavého průměru z konce presence (agregovaného pro m týdnů). Vlivem Vánoc lze očekávat vyšší prodeje v prosinci, a to se promítne i do prognózy lednových čísel, která bude pravděpodobně vyšší, než jaké budou opravdové prodeje.

Náchylnost na extrémy lze částečně odbourat využitím některého postupu pro průměrování s vytěsněním extrémních hodnot. Trimování (k extrémních hodnot je odstraněno, a průměruje se jen m-k hodnot) nebo Winsorizování (k extrémních hodnot je nahrazenou nejvyšší, respektive nejmenší hodnotou mimo množinu k). Účinnost obou postupů je srovnatelná.

Obecný matematický popis těchto 2 vztahů je následující (Jose & Winkler, 2008):

$$Trimmed\ mean = T(i) = \frac{1}{n-2i}\sum_{k=1+i}^{n-i} X_{(k)}$$

$$Winsorized\ mean = W(i) = \frac{1}{n}\left[iX_{(i+1)} + \sum_{k=1+i}^{n-i} X_{(k)} + iX_{(n-i)}\right]$$

Kde,

- *n = počet prognóz*
- *$X_{(k)}$ = hodnota k-té prognózy*
- *i = trimovací koeficient, z množiny $0 \leq i < n/2$*

Rovnice 2 Trimmed mean

Rovnice 3 Winsorized mean

3.4.2.1.2 Exponential Smoothing

Exponential smoothing je nejrozšířenější metodou prognózování na základě časových řad. Základní premisou je, že se jedná o vážený průměr v čase, kde je nejčerstvějším observacím přikládána větší váha než starším datům. (Chase, 2013)

Exponential smoothing je pospán následujícím vztahem (Elliott, Granger, & Timmermann, 2006)

$$m_T = \lambda \sum_{j=0}^{T-1}(1-\lambda)^j y_{T-j}$$

Kde

- *λ = vyrovnávací konstanta v rozsahu $0 < \lambda \leq 1$*
- *y = historická* hodnota v čase T-j (T = celkový čas, j = vzdálenost dané hodnoty od T)

Rovnice 4 Exponential smoothing

3.4.2.1.3 ARIMA

ARIMA je nejkomplexnější metodou forecastování pomocí časových řad. Z tohoto důvodu je také nejméně využívána, jelikož ne všichni prognostici mají potřebné technické know-how. Podstatou fingování ARIMA postupuje kombinace klouzavých průměrů, a regrese. Do důsledku se jedná o autoregresy, kde se identifikuje korelace mezi proměnou a tou stejnou proměnou v předcházejícím bodě v čase (Chase, 2006).

Pro techničtější popis postupu doporučujeme například (Elliott, Granger, & Timmermann, 2006).

3.4.2.2 Kauzální metody

Kausální metody vycházejí z předpokladu, že zkoumaná proměnná vykazuje vztah typu příčina-následek s jinými proměnnými (Sharma, 2006).

3.4.2.2.1 Lineární regrese

Lineární regrese je prognostický model, který předpokládá lineární – v přímce – závislost mezi dvěma proměnnými. Předpokládá, že proměnná, kterou prognózujeme, nazývaná závislá proměnná, má lineární vztah k jiné proměnné, nazývané nezávisle proměnná. Například, když předpokládáme že lidská váha a výška jsou lineárně závislé, tak můžeme udělat model lineární regrese tohoto vztahu. Poté můžeme model použít k tomu abychom předpověděli váhu člověka v závislosti na jeho výšce. Je také možné použít čas jako nezávisle proměnou, když chceme určit, jak se závisle proměnná s časem mění. V tomto případě použijeme model na předpovídání trendu. Lineární regrese vyžívá matematiky, aby proložila přímku napříč množinou dat, co je poté protažena do budoucna, kde vzniká prognóza. Vztah mezi dvěma proměnnými je dán rovnicí přímky (**rovnice 5**). (Sanders, 2016)

Rovnice 5 Lineární regrese

$$Y = a + bX$$

Kde

- *Y = nezávisle proměnná*
- *X = závisle proměnná. Proměnná, kterou se snažíme předpovědět*
- *a = průsečík osy Y*
- *b = sklon přímky*

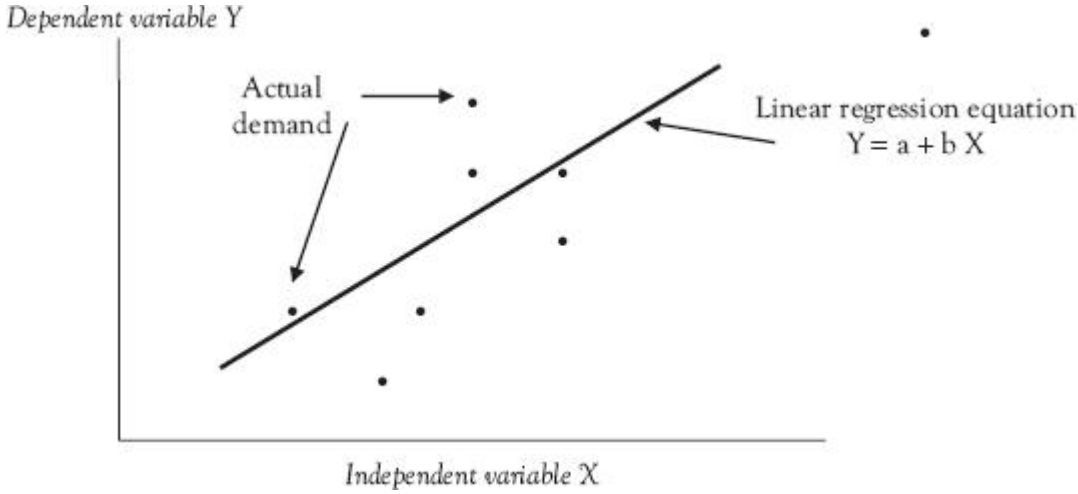

Obrázek 23 Lineární regrese

zdroj:(Sanders, 2016)

Použití lineární regrese vyžaduje nejdříve identifikaci matematického vztahu. Následně můžeme pro libovolnou hodnotu nezávisle proměnné spočítat hodnotu závisle proměnné, kterou chceme předpovědět. Čas může mnohdy být použit jako nezávisle proměnná, co umožňuje zobrazení lineárního trendu v čase. Tato metoda je snadná na pospání a vysvětlená. (Sanders, 2016)

3.4.2.2.2 Vícenásobná regrse

Vícenásobná regrese je rozšíření lineární regrese, tím že se zkoumá vztah mezi nezávislou proměnou a několika závislými proměnnými. Mnohdy existuje několik nezávislých proměnných, které mají dopad na závislou proměnou, kterou se snažíme předpovědět. V tomto případě je vícenásobná regrese kausálním modelem, kterých je vhodné použít. Vztah mezi proměnnými je dán **rovnicí 6** (Sanders, 2016)

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_{1k}$$

kde

- *Y = závislá proměnná*
- *β_0 = průsečík s osou y*
- *$\beta_1 \ldots \beta_k$ = koeficienty, které udávají míru vlivu nezávisle proměnných nezávisle proměnou*
- *$X_1 \ldots X_k$ = nezávisle proměnné*

Rovnice 6 Vícenásobná regrese

Příkladem je počet studentů nastupujících na univerzitu za semestr (závisle proměnná). Vliv na to mají nezaměstnanost a per-capita příjem v regionu (nezávisle proměnné, např. Předpoklad že hustěji obydlenější region budou mít větší absolutní zájem o univerzitní vzdělání, a movitější jedinci častěji aspirují k vysokoškolskému titulu. Další proměnné, které by model byl schopen zohlednit jsou sezónnost a trend, či některé výjimečné události. Výhodou vícenásobné regrese je schopnost předpovídat komplexnější jevy, Nevýhodou je potom vyšší náročnost na výpočetní kapacitu a data, ve srovnání s klasickou lineární regresí.

I když většina uživatelů spoléhá na výpočet regrese pomocí software, tak je zde několik doporučení

Využijte korelačního koeficientu (r) k měřená míry závislosti mezi proměnnými. Prakticky každá statistická softwarová sada by tento výpočet měla zvládat, r se i snadno interpretuje. Dosa-

huje hodnot od -1 (absolutní negativní vztah) do 1 (absolutní pozitivní vztah). 0 poukazuje na absence jakéhokoli vztahu mezi proměnnými. Korelační koeficient slouží k identifikaci proměnných, které by měl model obsahovat. Pokud jsou nezávisle proměnné silně korelované (r ≈1), tak stačí zohlednit jen jednu, jelikož ta druhá se bude chovat takřka identicky co se vlivu na závislou proměnou týká,

Pečlivě vybírejte proměnné, aby dávali smysl pro vaše potřeby. Zohledněte jak vhodnost pro váš model, tak prognózovatelnost. Když se hodnoty proměnných špatně určují, tak nemusí být nejvhodnější pro váš model. (Sanders, 2016)

3.4.2.2.3 Neurální Sítě

Neurální sítě (NN) se používají k prognózování od 90. let minulého století. Jedná se o nelineární třídu modelů s potenciálem zohlednit vysoké množství parametrů. Neurální sítě vykazují nejlepší výsledky pro opatrně vytřízená data o velkém objemu (tisíce observací), která vykazují nelineární závislosti. Na druhou stranu, jednoduší alternativy dominují pro menší objemy dat nebo v případech kdy jsou data protkány trendy a sezónností. (Sglavo, Tashman, & Gilliand, 2016). Autoři také komentují, že tyto závěry se ne nutně shodují s ostatní literaturou. Vysvětlují to neobjektivitou akademické publikační činnosti, kde je vyzdvihováno dosažení pozitivních výsledků (např. NN je prediktivně validní) a upozaďováno publikování závěrů negativních (např. NN mají nízko přesnost).

Princip fungování neurálních sítí je paralelní distribuované zpracování dat, což v praxi znamená, že se jedná o počítačový systém, který má paralelně sestavené obvody a kalkulace probíhají na několika výpočetních místech (uzlech) současně. Hlavní inspirací je architektura lidského mozku, kde synapse operují na podobném principu. (Zapranis & Alexandridis, 2014)

3.4.2.2.4 Bayesian Network

Bayesian Network (BN/Bayesovská síť) je nástroj rozhodování za nejistoty. Jedná se o rozdělení sdružené pravděpodobnosti, vyjádřené orientovaným, acyklickým síťovým grafem, kde uzly (N) představují proměnné a hrany (E) vazby mezi nimi, a hodnota každého uzle je dána podmíněnou pravděpodobností danou nadřazenými uzly. (Zeng, Jiang, & Neapolitan, 2016)

Obrázek 24 je ukázkou takové sítě, kde černě vyznačený uzel představuje výslednou prognózu. V tomto případě se jedná o model predikce risku kardiovaskulární příhody v nadcházejících 10 letech, který je v tomto případě 9.43%

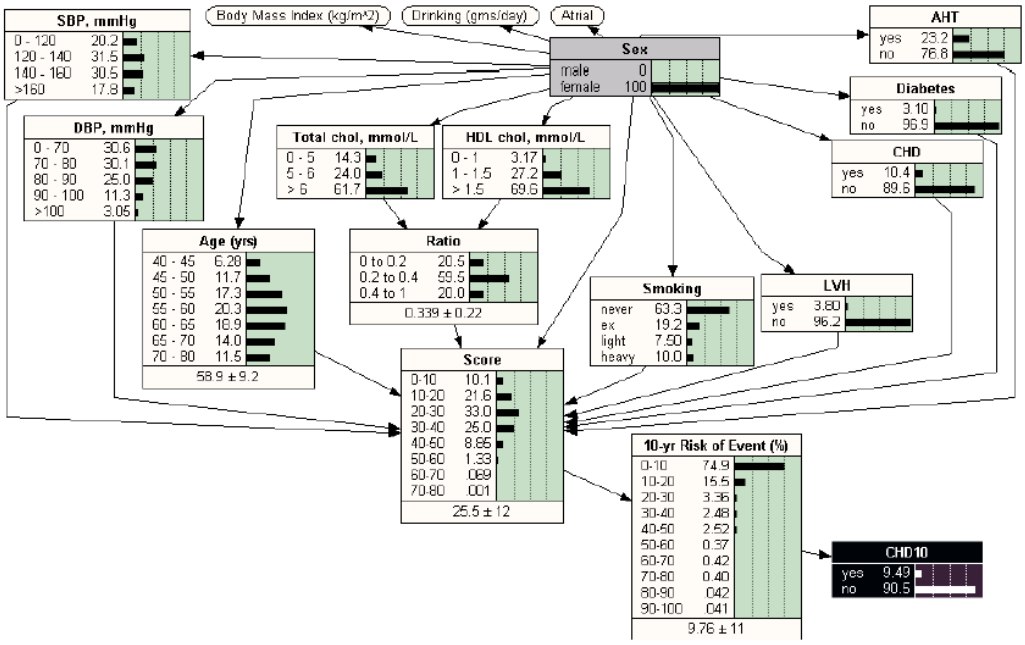

Obrázek 24 Bousselton Network

Zdroj: (Hope, Korb, Nicholson, & Twardy, 2008)

Každý z nadřazených uzlů udává úvodní pravděpodobnost dceřiným uzlům, a jejichž sdružená pravděpodobnost se upravuje v závislosti na změnách stavu úvodní pravděpodobnosti těchto uzlů. BN je tak koncipován jako nástroj rozhodování s neúplnými informacemi, kde na úvod dává prognózu na podobném principu jako lineární regrese – vztahu mezi proměnnými. Nicméně, jedná se o dynamický kauzální model, kde je forecast pro konkrétní případ zpřesňován v závislosti na nově dostupných informací (např. zde víme, že pacient je žena, což umožní upravit výsledky tak, že odhadují jen pravděpodobnost onemocnění u žen, nikoli celé společnosti). (Hope, Korb, Nicholson, & Twardy, 2008)

Hlavními omezeními BN jsou potřeba diskrétních proměnných, takže je nástroj vhodný pro předpovídání jevů, které se takto dají vyjádřit (např. binární). Duhům omezením je náročnost na vstupní data. Pro relevantní BN je potřeba poskytnout poměrně rozsáhlý vzorek dat, aby se daly správně určit úvodní pravděpodobnosti.

3.4.3 Kvalitativní metody

Druhou skupinou metod prognózování jsou kvalitativní nástroje, postavené na rozhodování jednotlivců a skupin, nikoli ryzí statistice.

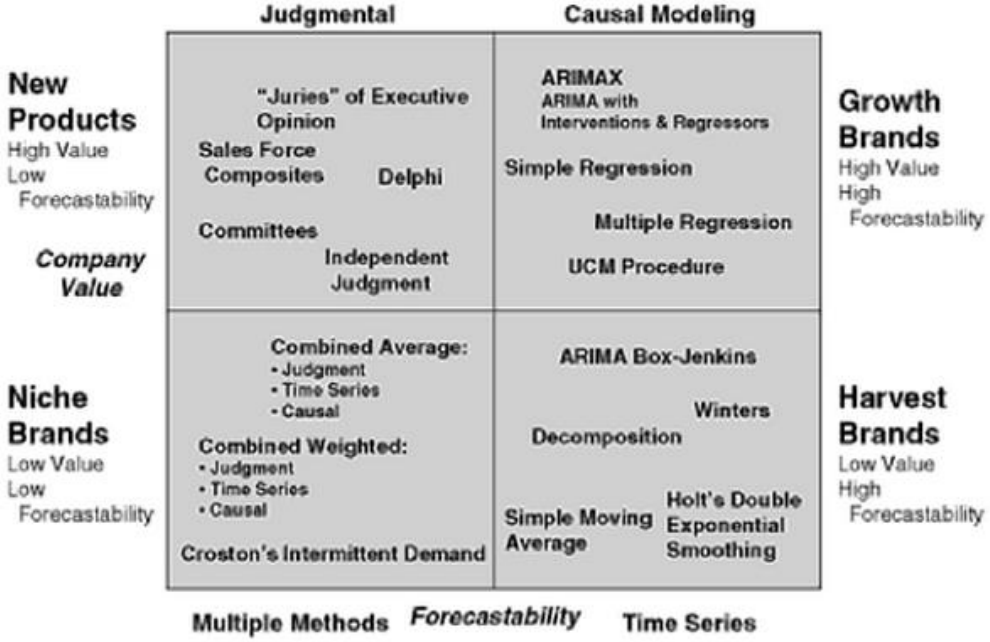

Obrázek 25 Matice prognostických metod a produktové segmentace z hlediska portfolio managementu

(Chase, 2013)

Navzdory rozšířenosti kvalitativních metod napříč prognostickou praxí, se doporučuje využívat tyto nástroje jen na případy kde není k dispozici dostatek data na využití metod kvantitativních. Případně, využívat judgmental metody jako složku celkové prognózy, v kombinaci s kvantitativními postupy (Chase, 2013).

Silnou stránkou kvalitativních metod je jejich agilita – rychlejší reaktivnost na zásadní změny situace, - zpravidla menší nákladovost, menší závislost na velkých a robustních zdrojích dat[29] a snažíš srozumitelnost stakeholderům. (Sanders, 2016)

Slabou stránku představuje lidský úsudek a motivace. V druhém případně je problém v upravování forecastu tak aby plnil jiné zájmy než objektivní popis reality. Jedním manifestem tohoto trendu je target setting, diskutován v **kapitole 3.4.1**. Co se úsudku týká, tak existuje velké množství výzkumu napříč několika obory (psychologie, behaviorální ekonomika atp.), které se shodují na faktu, že naše rozhodovací a prognostické schopnosti jsou subjektem mnohých omezení. Pro ilustraci uvedeme pár fenoménů, které se týkají naprosté většiny lidí. (Baron, Thinking and Deciding, 2008), (Kahneman, 2011)

- Anchoring – ovlivnění úsudku dostupnými numerickými daty, i když jsou zcela irelevantní
- Chyba hazardního hráče – neschopnost identifikovat jev závislí a nezávislí
- Optimismus

[29] Kvalita data hraje stále zásadní roli.

3.4.3.1 Individuální soud / Osobní odhad

Nejjednodušší metodou kvalitativního prognózování je individuální odhad prognostika. Mnohdy, ale ne vždy bez zohlednění kvantitativních nástrojů. Vhodnost je pro situace, kdy nelze vycházet z okolních dat (nedostatek, či nekvalita historických informací o problematice) či není k dispozici širší panel forecasterů, například vlivem omezeného času na dodání prognózy či potřeby utajení informací atp.

Empiricky je dokázáno, že zohlednění názoru, byť jen jedno další individua má pozitivní vliv na odhad, např. (Surowiecky, 2004), ale problém individuálního omezení lze z části odbourat opakováním vlastních odhadů a následné jejich agregace v čase.

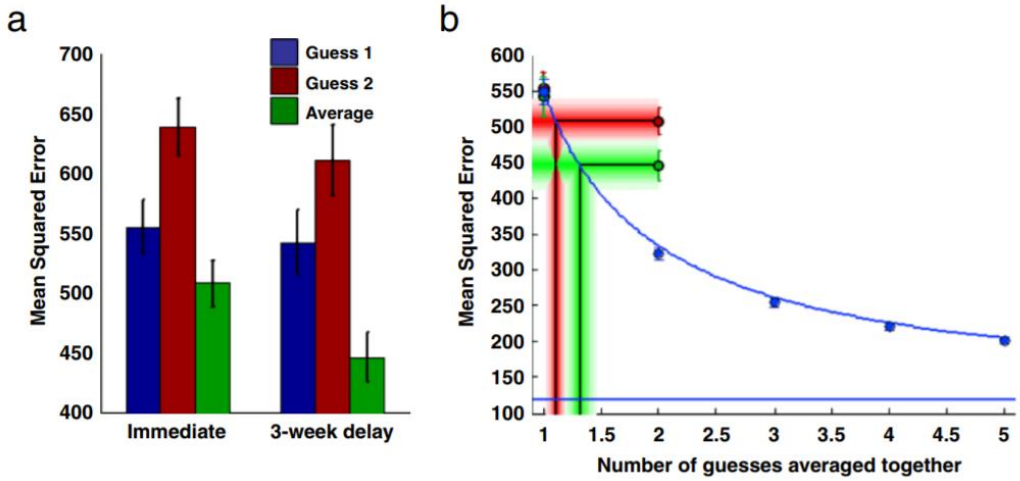

Obrázek 26 Agregace hodnot MSE pro iterované odhady jednotlivce

Zdroj:(Vul & Pashler, 2008)

(Vul & Pashler, 2008) ukázali, že průměrování prognózy jednotlivce má pozitivní dopady na jejich přesnost, a že časová odchylka (a) vede k přesnějším prognózám oproti těm, které po sobě následují v krátkém čase.[30] Iterováním tohoto postupu (b) lze dosáhnou ještě lepších výsledů, jelikož ukázali negativní závislost mezi počtem opakování a statistickou odchylkou prognózy založené na agregaci těchto opakování. (Fraundorf & Benjamin, 2013) podporují jejich, kde potvrzují jak zpřesňování na základě interní iterace, tak i lepší úspěšnost prognóz záložních na odhadu více lidí. Také dodávají, že v případech, kde má prognostik oborovou expertizu, tak může být lepší zvolit jeden lepší forecast, pokud je toho člověk schopen. Toto však není vždy podmínkou.

3.4.3.2 Panel expertů

Panel expertů je metoda prognózování na základě syntézy informací od několika individuálních prognostiků. Vychází z premisy, že zapojení víc lidí odbourá osobní nedostatky úsudku jedince. V literatuře se setkáte s označením „moudrost davu," a fenomén toho, že víc lidí souhrnně podává lepší informace než většina z nich jednotlivě se těší značnému zájmu literatury posledních 15 let. Nejznámější publikací na toto téma je pravděpodobně „The Wisdom of Crowds: Why the Many Are Smarter Than the Few and How Collective Wisdom Shapes Business, Economies, Societies and Nations" (Surowiecky, 2004), o kterou se z části opírá i tato práce. Dnes se tento trend formálně promítá do širokého pásma činností, včetně aplikací v softwarovém inženýrství, kde bychom využití tohoto kognitivního fenoménu nemuseli očekávat. (Zimmermann & Menzies, 2016).

[30] Dotazovaní měli odhadnou proporci letišť v US z celkového počtu na světě

Původ tohoto konceptu se však datuje již do roku 1907, kde ho Anglický myslitel Francis Galon popsal v časopise Nature. Jeho experiment spočíval v tom, že nechal dav odhadovat váhu vola na trhu, a i když byli jednotlivé hodnoty značně nepřesné, tak jejich průměr se skutečnosti přiblížil na 0.083 % (Galton, 1907).

Procesně je tato metoda poměrně flexibilní. Více méně spočívá v tom, že k sobě dáte několik lidí, u kterých se předpokládá expertiza v probírané problematice. Následně zpravidla následuje volná diskuse, kde dojde panel k prognóze. Jak z popisu vyplívá, lze za panel expertů považovat takřka jakoukoli metodu která postavena na úsudku více lidí. Více cíleně lze za metodu panelu expertů označit takové postupy, které dávají tomuto postupu alespoň nějakou strukturu. Vzhledem ke své povaze se jedná o variantu BOGSAT metod. (Sanders, 2016), (Potůček, 2006). Hlavním nedostatkem této metody je náchylnost na sociální dynamiku skupiny. Může se snadno stát, že zbytek panelu se podřídí svému dominantnímu členu, případně svému nadřízenému, pokud panel sestává z účastníků napříč organizací. Zásadní roli pro tuto sociální dynamiku může hrát kulturní zázemí členů panelu. Jak organizační, tak národní, vzhledem k faktu, že percepce rozdílu mezi sociálním postavení jedinců hraje míru na předpoklad participace. (organizations, 2003)

3.4.3.3 Delphi

Delphi je v podstatě variací na metodu panelu expertů, kde se vybraná skupina jedinců snaží dospět k výsledné prognóze dosažením konsensu.

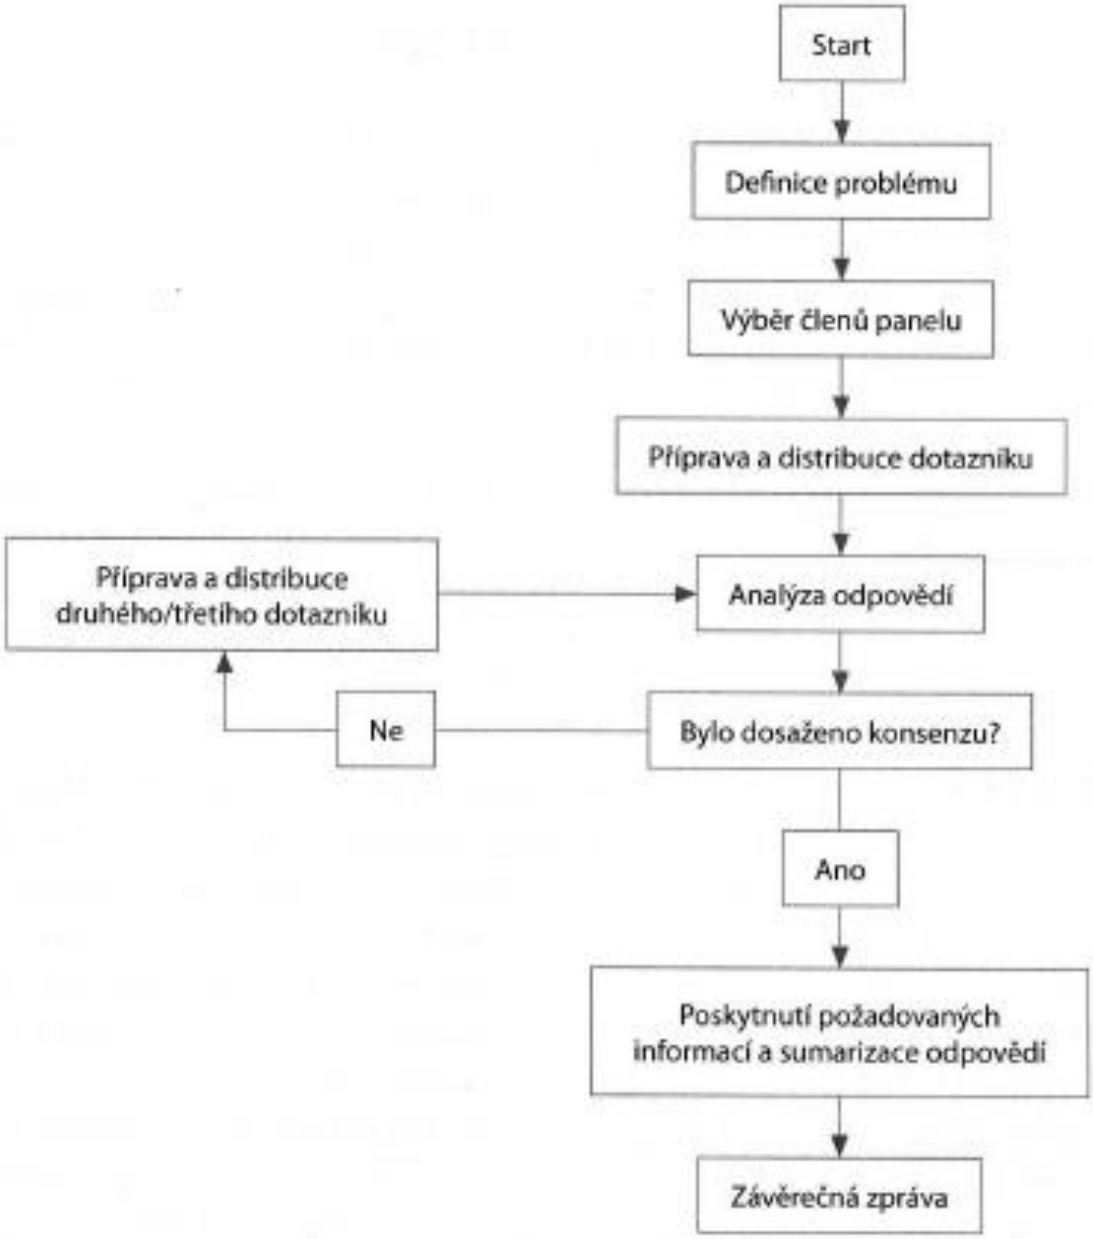

Obrázek 27 Obecné schéma metody delphi

Zdroj: (Potůček, 2006, str. 143)

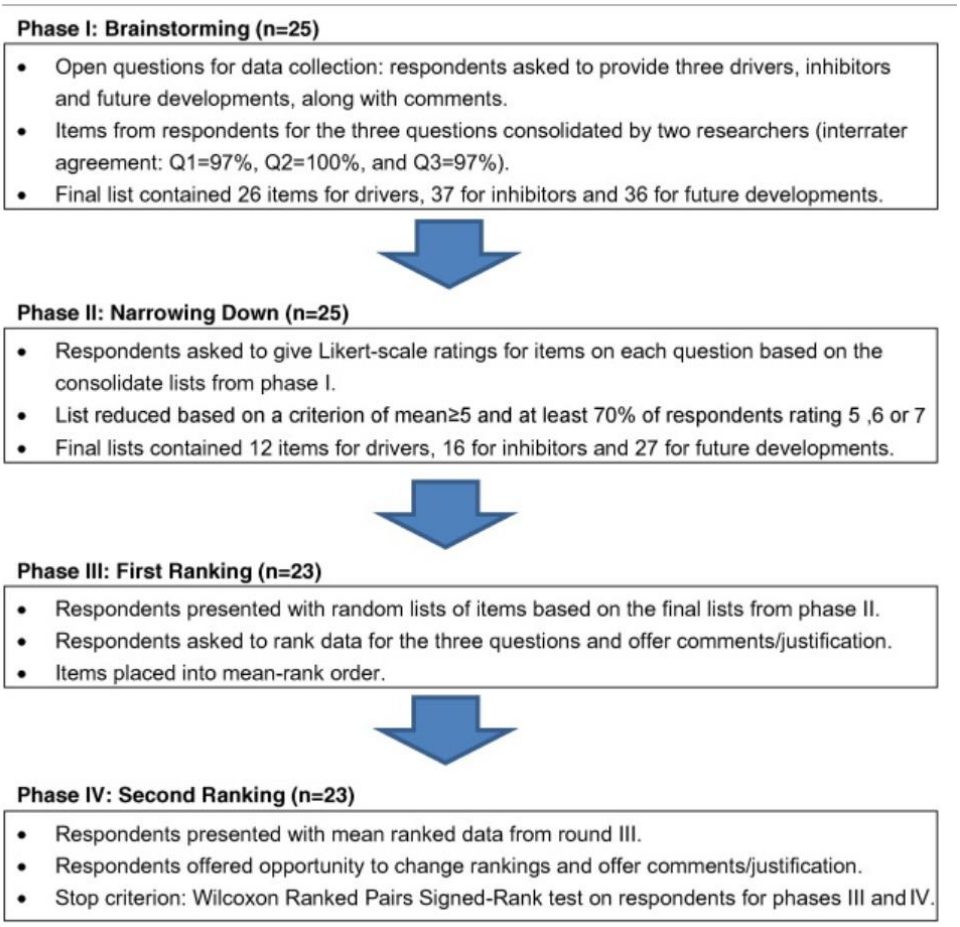

Obrázek 28 Konkrétní implementace iteračních kroků metody delphi

zdroj:(Barnes & Mattson, 2016)

Na **obrázku 28** je vidět obecná struktura modelu delphi, a **obrázek 29** zobrazuje možnou konkrétní implementaci kroků v iterativní části – v tomto případě studie faktorů ovlivňující rozšiřování trendu sdílené ekonomiky ve společnosti.

Procesně dělohy spočívá v iterativním dotazování a snahy dosáhnout konsensu panelu expertů. Jedná se o více kolovou metodu, kde jsou v prvním kole respondentům položeny otázky, které se v kolech následujících opakují (případně s upřesněními) a jsou doplněny o informace od ostatních respondentů ve studii. Toto opakování si dává za cíl dosáhnou názorové konvergence, výsledný forecast je hodnotou právě takto dosaženého konsensu. Zpravidla vyobrazen s mírou rizika, jelikož nelze očekávat, že se panel shodne přesně na konkrétním jevu, ale jejich názory se k sobě budou blížit s jistou tolerancí,

Jednou z výhod metody je anonymita a decentralizace sbírání odpovědí, což odbourává velkou část problémů standardního panelu expertů. Vzhledem k odbourání role sociální dynamiky, se metoda delphi ukazuje jako nejvhodnější z kvalitativních metod využívající více aktérů. (Gnatzy, Warth, von der Gracht, & Darkow, 2011), (Rowe & Wright, 1999).

Jako každý proces, se ani metoda delphi neobejde bez problémů. Jedná se o časovou náročnost. Například již zmiňovaná studie (Barnes & Mattson, 2016) měla délku každého kola jeden měsíc, a mezi tím měsíční pauzy. Tato konkrétní implementace je tedy výrazně vhodnější pro strategické prognózování, a již méně pro operativní. Druhým nedostatkem je citlivost na vhodně zvolené respondenty. I za předpokladu přidané hodnoty expertízy nemusí nutně být snadné vybrat experta z oboru. Předpoklad znalosti domény člověka z oboru může vést k false positive chybě, jelikož mají profesionálové konvergovat k lukrativnějším oborům což v některý případech ztěžuje

výběr. (Organisation, 2004). Druhým aspektem výběru respondentů je právě zmiňovaná časová náročnost procesu, tudíž je potřeba zajistit jejich retenci. (Potůček, 2006)

(Gordon & Pease, 2006) a (Gnatzy, Warth, von der Gracht, & Darkow, 2011) se snažili odbourat časovou náročnost modelu implementací real-time delphi modelu, který nahrazuje fixní cykli real-time komunikací přes synchronní online portál. Jejich poznatky ukazují, že toto může být optimální implementace modelu. V obou případech si ponechal prediktivní validitu a zároveň měl vyšší retenci respondentů ve srovnání s konvenční metodou.

3.5 Hodnocení prognózování

Následující kapitola je plně převzata z autorova bakalářské práce, „Kvalitativní prognózování – moudrost davů v Praxi" z roku 2015. (Prošek, 2015)*. Jak novější vydání primární literatury,* (Chase, 2013)*, tak i nově zkoumané prameny,* (Sglavo, Tashman, & Gilliand, 2016)*, ukazují na pokračující aktuálnost informací a závěrů.*

Dnešní normou organizačního chování je hodnotit jednotlivé zaměstnance a hledat zlepšení v deficitních oblastech; vyhodnocovat úspěšnost produktů a nahrazovat psy[31] lukrativnějšími produkty. Absence hodnotících metrik pro kteroukoli z uvedených komponentů fungování a vývoje organizace by byla považována za pochybení, přesto se prognózování zdaleka netěší takové pozornosti, a mnohé firmy vyhodnocují přesnost svých prognostických procesů jen čtvrtletně nebo dokonce nikdy, a mnohdy na nedostatečně konkrétní úrovni[32] (Chase, 2006).

Výrazné překonání prognózy po poptávce lze interpretovat jako úspěch pro fungování podniku; bohužel to také znamená nezanedbatelnou chybu prognózy, která s sebou může nést značné ztráty (respektive realizované náklady). Významným dopadem překonání prognózy poptávky je buď ztráta příjmů z prodejů, které není podnik schopný realizovat, nebo backordering. V obou případech je negativně ovlivněna spokojenost zákazníků – nemožností získat, co chtějí, nebo jejich vystavení časové prodlevě. Backordering také značně zatěžuje řízení zásob, vedoucí ke generování nadbytečných nákladů. Jak prognostici, tak uživatelé by si proto měli uvědomit, že překvapivá výkonnost podniku nemusí být jen známkou jeho síly, ale i symptomem chyb prognostických procesů.

Hodnocení prognostické praxe v podniku vychází ze dvou základních potřeb; 1) měřit vlastní výkonnost užívaných metod a 2) porovnání s alternativními metodami, jejichž uplatnění v budoucnu by mohlo být vhodnější než současné metody (Chase, 2006).

Jednou z objektivních metrik pro vyhodnocování prognóz za konkrétní časový úsek je určení odchylky (chyby) hodnot pozorovaného jevu od hodnoty prognózy, která je vyjádřena následujícím vztahem:

$$Error = e_t = A_t - F_t$$

Kde:

- *et = chyba prognózy v časovém úseku t*
- *At = skutečná hodnota prognózovaného jevu v časovém úseku t*

[31] BCG matic (Picardo, 2014)

[32] Vhodnější je vyhodnocovat prognózy na úrovni SKU než na vyšších souhrnných úrovních.

- *Ft = hodnota prognózy v časovém úseku t* (Chase, Demand-driven forecasting, 2006)

Rovnice 7 Prognostická chyba A-F

Interpretací je hodnota, o kolik prognóza překonala nebo podhodnotila vlastní hodnoty jevu. Navzdory jednoduchosti tohoto vztahu existuje početný tábor zastánců opačného zápisu vztahu pro chybu prognózy (Chase, 2006).

$$Error = e_t = F_t - A_t$$

Rovnice 8 Prognostický Chyba F-A

I když se rozdíl může zdát jako triviální, tak má dopady na hodnoty běžněji používané metriky, kterou je relativní chyba (PE). (Green & Tashman, 2010)

$$PE = \frac{F_t - A_t}{F_t}$$

Rovnice 9 Relativní chyba (F-A)

$$PE = \frac{A_t - F_t}{A_t}$$

Rovnice 10 Relativní chyba (A-F)

Rozdíly mezi formulací 4a a 4b lze snadno ilustrovat na příkladu s bezrozměrnými, bezčasovými hodnotami A = 100, F = 120 (80).

Tabulka 1 Rozdíly ve formulaci PE jako A-F oproti F-A

	A = 100, F = 120	A = 100, F = 80
PE = (F-A)/F	0,166666667	-0,25
PE = (A-F)/A	-0,2	0,2

Zdroj: autor

Z tabulky 1 je zřejmé, že výsledná hodnota je závislá na způsobu formulace PE. Musíme si také povšimnout vlastnosti formulace 4b, která podává symetrické výsledky pro nadhodnocenou a podhodnocenou prognózu, kdežto formulace 4b akcentuje nedostatečnou prognózu ve srovnání s nadhodnocenou.

V praxi se nesetkáváme s hodnotami individuálně, ale s jejich souborem, proto je nejběžněji používaným ukazatelem přesnosti prognózy průměrná absolutní procentuální chyba (mean absolute percentage error – MAPE), který je vyjádřen následujícím vztahem (Chase, 2006):

$$MAPE = \frac{1}{n}\sum_{t=1}\frac{|A_t - F_t|}{A_t} * 100$$

Kde

- *A_t = skutečná hodnota prognózovaného jevu v časovém úseku t*
- *F_t = hodnota prognózy v časovém úseku t*
- *n = počet časových úseků¨*

Rovnice 11 MAPE

Při aplikaci MAPE je nutno vzít v potaz dvě vlastnosti této metody. MAPE není vhodná pro situace, kdy se skutečné hodnoty prognózovaného jevu blíží nule (nebo jsou rovny nule), jelikož v těchto případech udává přehnané hodnoty chyby.

Druhou vlastností je jistá míra manipulovatelnosti, díky předpojatosti vůči podhodnocování. Pohledem na extrémy zjistíme, že chyba v případě, kdy prognóza podhodnotí jev, může být maximálně 100 %, kdežto v opačném případě neexistuje limit. Tento poznatek je především důležitý, pokud se na prognózování podílí lidé, kteří mohou mít zájem na nižší hodnotě zjištěné chyby. (Chase, 2006)

Populární alternativou k MAPE je symetrické MAPE (sMAPE), které využívá průměr naměřených (A) a odhadových (F) hodnot jako dělitel:

$$sMAPE = \frac{1}{n}\sum_{t=1} \frac{|A_t - F_t|}{\frac{1}{2}(A_t + F_t)} * 100$$

Rovnice 12 sMAPE

(Green & Tashman, 2010)

Hodnocení prognostických metod může být buď na základě matematického vyjádření, jak popsáno výše, nebo na základě metodického rozboru. Armstrong a kol. dospěli na základě studia dostupné literatury k tzv. zlatému pravidlu prognózování (golden rule of forecasting), které představuje soubor postupů, jichž by se měla každá prognostická metoda držet. Jejich výzkum ukazuje, že porušení kterékoli jedné z položek seznamu obecně zvýší chybu prognózování o 44 %. Položky zlatého pravidla byly konsolidovány do kontrolního seznamu[33], který umožňuje jak prognostikům, tak uživatelům snadno zhodnotit různé prognostické postupy. (Armstorng, Green, & Graefe, 2015)

[33] Příloha 1

4 Analytický model prognózy úspěšnosti crowdfudingu

Následující část práce se bude věnovat praktickému propojení poznatků z forecastingu a jejich aplikace. Předmětem našeho výzkumu bylo sestavení několika kvalitativních modelů a identifikace míry vlivu některých parametrů na úspěšnost crowdfundingových kampaní. Závěrem této části, respektive celé diplomové práce, budou praktická doporučení nejen pro začínající podnikatele, kteří se rozhodnou financovat svůj podnik pomocí peněz davu.

Krom této úvodní části, kde vymezím základní parametry výzkumu bude níže věnován patřičný prostor pro zpracování vstupních dat a následný benchmarking primárního modelu s čirou náhodou a statistickým modelem.

Vlastní výzkum se primárně zaměřuje na působení na platformách Kickstarteru a Indiegogo. Motivací nám především bylo jejich dominantní postavení, a dosavadní výlučná pozice odměnového crowdfundingu jako takového.

Vzhledem k legislativní nejistotě panující v prostředí investičního crowdfundingu jsme se rozhodly na tento směr nezaměřovat. Případným zájemců o další výzkum tématu nicméně doporučíme využít dat Komise pro kontrolu cenných papírů Spojených států (SEC). Kvartálně zveřejňují finanční výkazy všech společností financovaných pomocí investičního crowdfundingu ve spojených státech.[34]

Ze zbývajících dvou forem jsme obě vyloučili z následujících důvodů. Charitativní platformy byly vyloučeny již na začátku, jelikož se zaměřujeme na podnikatelskou aktivitu, kdežto financování altruistických pohnutek se může řídit jiným motivačními faktoru, a tudíž by modelování na tomto typu crowdfundingu neplnilo záměr. Zvážili jsem i možnou analýzu P2P lendingu, ale ta se za prvé potýká také s jistou legislativní

[34] https://www.sec.gov/ respektive https://www.sec.gov/dera/data/crowdfunding-offerings-data-sets

4.1 Získání, validace a čištění dat

K diplomové práci využíváme agregát veřejných dat minulých crowdfundingových kampaní, který byl veřejně k dispozici z www.thecrowdfundingcenter.com. Jedná se o poskytovatele analytiky a business intelligence okolo crowdfundingu. Krom vlastní business inteligence byl zde i k dispozici poměrně rozsáhlý dataset, obsahující informace z několika největších platforem.

Hrubá data představovala údaje o 13 206 crowdfundingových projektů, ze kterého jsme se rozhodly sestavit Beyesovu síť a otestovat na ní její prediktivní validitu. Nicméně, samotné stavbě analytického modelu muselo předcházet další zpracování dat. Z části zde byly obsaženy nekvalitní data – především se jednalo buď o data neúplná, nebo o nějaký velice úzký susbet který sice může být validní v některých případech, ale není reprezentativní pro systém financování crowdfundingem jako takovým. Přesné kroky budou adresovány dále.

Vlastnímu čistění nicméně předcházela kontrola validity dat jako takových. Vzhledem k tomu, že pocházejí ze soukromého zdroje 3. strany tak jsme chtěli mít jistotu, že opravdu odpovídají skutečnosti. Provedly jsme náhodný výběr menší části dat, kterou jsme přímo ověřovaly na stránkách individuálních projektů, jestli data odpovídají. Vzhledem k celkovému objemu jsme chtěli zaručit, že budeme mít statisticky významem vzorek na ověření, a tak jsme vybrali 300 projektů které jsme postupem času prošli. Vzhledem k centrální limitní větě bylo možné tento postup zvolit, jelikož se binomické rozdělení (zkoušíme jen pravdu nebo nepravdu) chová při dostatečně velkém rozsahu přibližně jako rozdělení normální. (Weisstein, 2019)

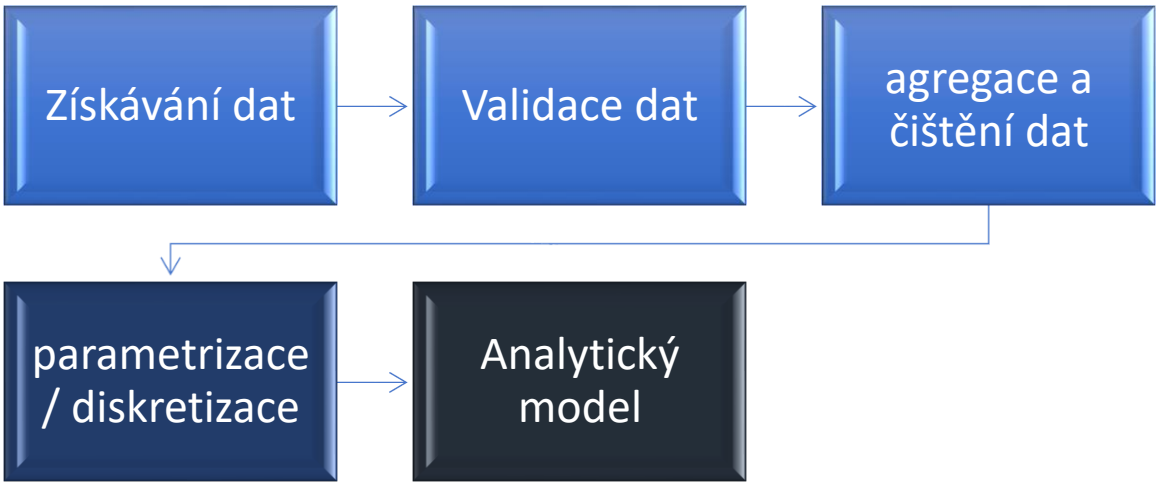

Obrázek 29 Získávání a příprava dat jako vstupu do analytického modelu

zdroj: autor

Provedeny byly dvě základní skupiny úkonů. Odstraňování problematických dat a následná parametrizace vyhovujících pro využití v analytickém modelu a při jeho benchmarku. V prvním případě bylo nejdříve odstraněno 365 záznamů které nespadali do odměnového crowdfundingu. Dalších 360 položek bylo z jiných platforem než Indiegogo nebo Kickstarter, a jejich relativně malé množství by nestačilo k tréninku BN aby mohlo jejich roli zohlednit. Dalším krokem jsme se opřeli

o výzkum Brendona Lichtiga (2105), který poukazuje na kampaně s 0 přispěvovateli jako na podezřelé, takže jsme je odstranili. 268 bodů bylo odstraněno pro chybějící geografické údaje a 11 projektů s jednodenní živostností bylo odstraněno pro jejich nereprezentativnost. (Lichtig, 2105)

Krom odstraňování dat jsme doplnili geografická data každého projektu o kontinent, zakládající se na ISO Alpha-2 označení.[35] Druhým doplněním byla normalizace finančních hodnot pomocí převedení všech hodnot na americký dolar. Například, cílová částka pro financování byla zveřejněna jen v lokální měně. Ke konverzi byl použit odvozený kurz – poměr mezi celkově vybranými prostředky v USD a jiné měně, jelikož byli obě tyto hodnoty dostupné. Využitím vnitřního směnného kurzu (FX) bylo především zamezeno vnitřním nekonzistentnosti.

Výsledkem procesu, a již zmiňované diskretizace, byl čistý dataset o 8871 položkách, který sloužil jak k trénování modelu, tak jeho testování. Samozřejmě to neprobíhalo na stejných datech a celý soubor byl rozdělen na training dataset o 7771 položkách a testing dataset o 1000 položkách.

4.2 Parametrizace a disrketizace dat

Vzhledem k povaze Bayesovy sítě není vhodné využívat kontinuální proměnné, což byl jeden z důvodu diskretizace dat. Nicméně, ještě je nutné zohlednit přehlednost modelu a prediktivní validitu jednotlivých možných stavů parametrů. Proto jsme se u každého z nich zastavili a zjišťovali, jestli je potřeba nějaké agregace.

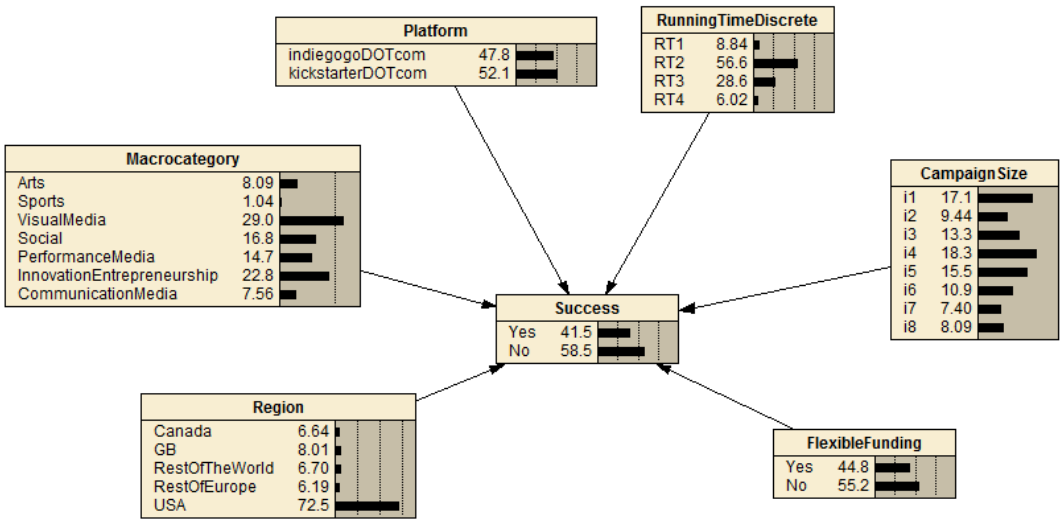

Obrázek 30 BN model metadat crowdfundingových kampaní (vlastní výzkum)

zdroj:Autor

Vlastní konstrukce síťového modelu bude ještě zmíněna, ale na **Obrázek 30** BN model metadat crowdfundingových kampaní (vlastní výzkum)

zdroj:Autor jsou vidět jednotlivé vstupní parametry které ovlivňují forecast.

[35] https://github.com/lukes/ISO-3166-Countries-with-Regional-Codes

1. **Platforma (Platform):**[36]

Jak již bylo avizováno v úvodní části práce, tak se jedná o dva největší platofrmní hráče na poli s crowdfundingem. Hlavním důvodem jejich zařazení jsou ale odlišnosti v přístupu k financování tak i produktovému managementu, kde je Indiegogo více inklusivní z těchto dvou firem. Vzhledem k binární piovaze proměnné nebylo v této části potřeba dalšího zpracování.

- **Délka kampaně / délka investičního kola (RunningTimeDiscrete}**

Další z faktorů, na který jsme se zaměřovali byla trvanlivost kampaní na zafinancováni projektu. Intuitivně by se dalo očekávat, že čím delší kampaň tím lepší šanci na získání prostředků bude subjekt mít. Nicméně, jak bylo zmíněno v úvodu práce, empirická data doposud hovoří o opaku. Dnes ani není výjimkou že sami platformy z těchto a dalších důvodů čas na jeden projekt omezují. Konkrétně Kickstarter má zavedený horní strop 60 dnů.

Vzhledem k faktu, že jedno-denní inkrementy trvání kampaně mají takřka kontinuální povahu pro naše potřeby, tak zdej již k modifikacím dojít muselo.

Tabulka 2 Diskretizace BN - Délka Kampaně

zdroj: Autor

Ozančení (využito v BN)	Dolní mez	Horní mez	Velikost podmnožiny	Relativní velikost podmnožiny
RT1	0	20	686	8.83%
RT2	21	40	4396	56.57%
RT3	41	60	2222	28.59%
RT4	61	120	467	6.01%

Principiálně byly data seskupeny do 5 stejně dlouhých interval. Nicméně RT5 (80-100) a RT6 (101-120) představovali souhrnně méně než 1% dat, a RT4 byl namísto nich rozšířen aby pojal i long-tail data.

- **Kategorie (Macrocategory).**

Třetí ze zkoumaných proměnných se stala kategorie projektu. Obě platformy podporují širokou paletu možných zařazení. Je na snadě předpokládat, že ne všechny profilace mají stejný potenciál na zisk kapitálu. Z dlouhodobého hlediska je i možné, že některé specialisované platformy si vykleští vlastní niku tak dokonale, že universální platformy nebudu schopny do takové míry reagovat na požadavky zákazníků.

Data vykazovala 25 unikátních kategorií, což se jevilo jako nevhodné vzhledem k menšímu než 1% podíl na celkovém objemu. Proto došlo k agregaci původních kategorií do následujících sedmi makrokategorií.

[36] Označení uzlů v této části práce je ve formátu "České označení (označení v modelu)"

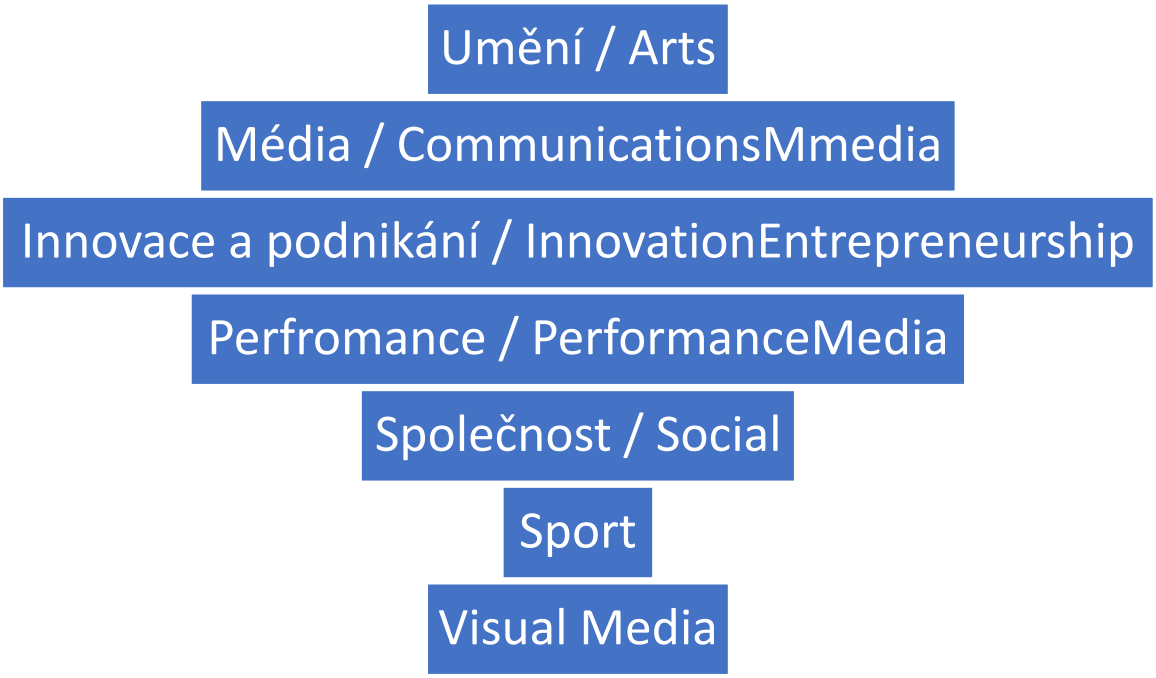

Obrázek 31 Diskretizace BN – Kategorie

zdroj: Autor

- **Geografie (Region)**

Převážná většina crowdfundingových peněz přichází ze spojených států, a nejinak tomu bylo i v našem data-setu. Je teda potřeba říci, že tady jde spíš o množství zájemců o peníze, než ty peníze v první čadě. Nicméně, obě tyto skupiny jsou značně provázány a regionální příslušnost hraje stále roli.

Geografická data měli stejný problém jako kategorie, a to byla velmi vysoká míra fragmentace uvnitř dat. Původní záměr seskupit účastníky čistě podle geografie musel být upozaděn, takže jsme rozdělili data podle velikosti crowdfundingového trhu, a hypotetizovanou vyspělostí s ním spojenou.

Tabulka 3 Diskretizace BN – Geografie

zdroj: Autor

Region	No. of entries	% of total
USA	5634	72.50%
GB	622	8.00%
Rest [of the world]	520	6.69%
Canada	515	6.63%
Rest of Europe	480	6.18%

- **Způsob financování (Flexible funding)**

Jedná se o binární parametr, a princip je nastíněn **kapitole 2.3.1.1**. této práce. Je zde ale nutná poznámka směrem k Indiegogo, jelikož očekáváme nezanedbatelnou míru korelace mezi flexibilním financováním a platformou, která to umožňuje. Na druhou jsme chtěli parametr zahrnout jako jistou formu kontroly, jelikož Indiegogo umožnuje se rozhodnout mezi oběma formami.

- **Finanční cíl (CampaignSize)**

Předposledním zohledňovaným prediktorem je cílová částka, kterou podnikatel (zakladatel projektu) vytyčil. Lze očekávat, že s rostoucí ambicí klesá zájem lidí investovat do podniku pomocí crowdfundingu. Obzvláště moonshot projektům, kterými označujeme přehnaně ambiciózní cíle, se na Kickstarteru či Indiegogo nemusí dobře dařit. Při zvýšené kapitálové zátěži již stojí alespoň za zvážení investiční crowdfunding, pokud to lokální legislativa dovoluje. Případně I obyčejný rizikový kapitál, venture a angels, kteří jsou lépe připraveni zareagovat na potřeby větší investice.

Z hlediska zpracování zde platí podobná omezení jako u doby trvání. To znamená, že finanční cíle je v agregátu také nutné rozdělit na několik intervalů. Ještě podotkněme, že v platí obecné očekávání lepšího úspěchu méně ambiciózních kampaní.

Tabulka 4 Diskretizace BN - Finanční Cíl

zdroj: Autor

Label	Nižší mez ($)	Vyšší mez ($)	Počet projektů v intervalu
i1	0	1,000	1327
i2	1,001	2,000	733
i3	2,001	4,000	1035
i4	4,001	8,000	1419
i5	8,001	16,000	1207
i6	16,001	32,000	847
i7	32,001	64,000	575
i8	64,001	∞	628

Z dat je patrné, že většina aktivních crowdfunderů přijímá výše nastíněnou tezi, a drží se v okolí spodní hranice.. Tento fakt vedl I k poměrně extrémní intervalizaci, kde jsme adoptovali exponenciální růst intervalů, co akorát dostupná data vyrovnalo do přibližně normálního nebo centrovaného trojúhelníkového rozdělení.

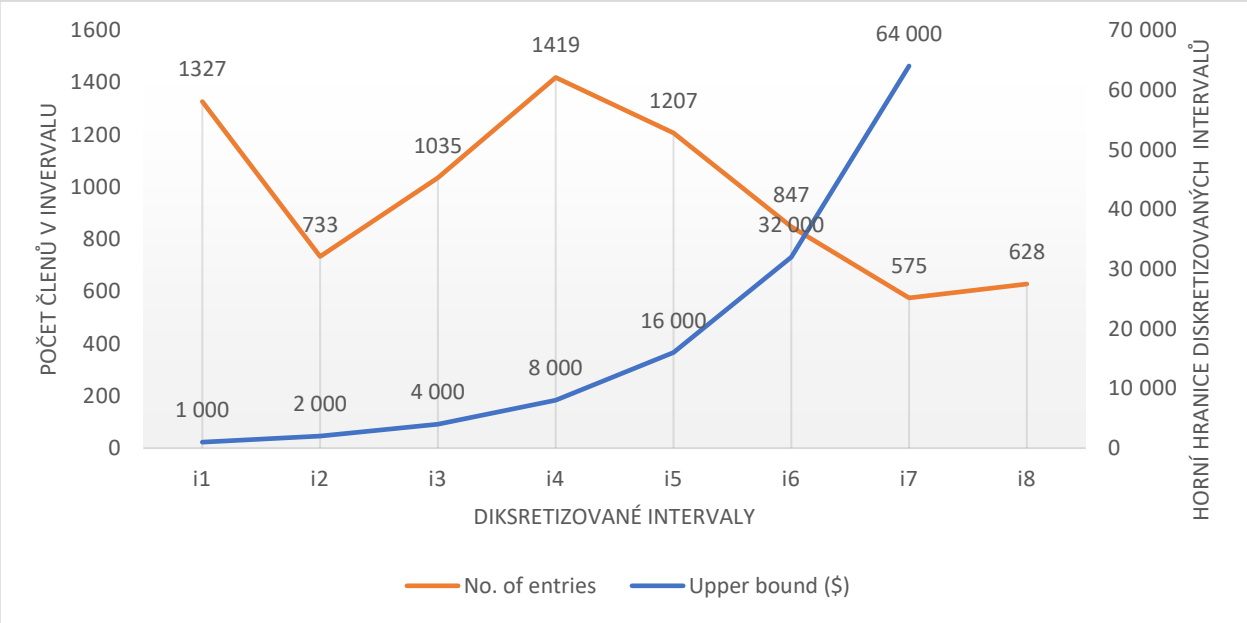

Obrázek 32 Graf diskreditované distribuce Finančních cílů a zobrazení exponenciálního růstu intervalů

Zdroj: Autor

Krom prediktivních parametrů reprezentujících uzly Bayesovi sítě obsahuje model i binární parametr pro vyhodnocení.

4.3 Konstrukce modelu a testování

Jak již bylo uvedeno v **kapitole 3,** kde byly probírány prognostické nástroje včetně BN, tak se jedná o pravděpodobnostní síťový graf, který využívá inference k postupnému zpřesňování prognózy.

Inferenční povaha modelu také napovídá, proč byl vybrán pro potřeby námi generované prognózy na místo jiných postupů. Hlavním důvodem je právě schopnost pracovat s kauzálními daty nezávislými na čase. Crowdfunding je perfektní případ jevu, který je velice založen na mezilidských interakcí, takže mnohem častěji dochází k akci na základě nějaké příčiny, na místo uplynutí času.

Níže si dovolím poskytnout I matematické vyjádření pro úplnost. Je nutné však podotknout, že pro náročnost ruční výpočet nedoporučuji.

$$P(\emptyset/X) = \frac{P(X/\emptyset) * P(\emptyset)}{P(X)}$$

$$P(\emptyset/X) = P(X/\emptyset) * P(\emptyset),$$ *pro P(X)=1*

Kde

- *P(ϑ) je základní očekávaná pravděpodobnost (prior belief)*
- *P(X) je pravděpodobnost nastání kornatí jevu X*
- *P(X/ϑ) je podmíněná pravděpodobnost jevu X za předpokladu že nastane ϑ*
- *P(ϑ/X) je podmíněná pravděpodobnost jeví ϑ za předpokladu, že nastane X*

(Tanjin, Khan, & Imtiaz, 2019)

Rovnice 13 Podmíněná pravděpodobnost

Rovnice 14 Podmíněná pravděpodobnost, kde P(X)=1

Rovnice 14 zřejmým důsledkem rovnice číslo jedna, až by se zde dala považovat za redundantní. Nicméně tento proces je podstatou celého BN. Jakmile se změní pravděpodobnost jevu předcházejícího, tak tato změna bude propagovat celým systémem a podle vzájemných vazeb se budou někteří stavy stávat vice či méně pravděpodobně.

PercentFunded Table (in Bayes net final_project)

Node: PercentFunded

Chance | % Probability

Apply | OK | Reset | Close

FlexibleFunding	Platform	RunningTime	CampaignSize	Category	Region	PF1	PF2	PF3	PF4	PF5
Yes	indiegogoDOTcom	RT1	i1	VisualMedia	Canada	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	VisualMedia	GB	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	VisualMedia	Europe	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	VisualMedia	RestOfTheWorld	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	VisualMedia	RestOfEurope	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	VisualMedia	USA	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Sports	Canada	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Sports	GB	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Sports	Europe	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Sports	RestOfTheWorld	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Sports	RestOfEurope	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Sports	USA	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Social	Canada	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Social	GB	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Social	Europe	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Social	RestOfTheWorld	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Social	RestOfEurope	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	Social	USA	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	PerformanceMedia	Canada	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	PerformanceMedia	GB	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	PerformanceMedia	Europe	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	PerformanceMedia	RestOfTheWorld	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	PerformanceMedia	RestOfEurope	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	PerformanceMedia	USA	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	InnovationEntrepreneurship	Canada	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	InnovationEntrepreneurship	GB	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	InnovationEntrepreneurship	Europe	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	InnovationEntrepreneurship	RestOfTheWorld	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	InnovationEntrepreneurship	RestOfEurope	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	InnovationEntrepreneurship	USA	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	CommunicationMedia	Canada	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	CommunicationMedia	GB	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	CommunicationMedia	Europe	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	CommunicationMedia	RestOfTheWorld	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	CommunicationMedia	RestOfEurope	20	20	20	20	20
Yes	indiegogoDOTcom	RT1	i1	CommunicationMedia	USA	20	20	20	20	20

Obrázek 33 CPT BN aplikovaného na crowdfunding (vlastní výzkum)

zdroj; Autor

Součástí každého modelu právě uchování podmíněných pravděpodobností, tzn. všech možných kombinací pravděpodobností které mohou v rámci systému nastat. Celkový rozsah CPT (tabulky podmíněných pravděpodobností) tak závisí na počtu proměnných a počtu možných stavů každé proměnné. Ve zdejším případě se jedná o 18,144 kombinací pravděpodobností které mohou nastat pro dceřiný uzel kde se sjednocují vliv výše probíraných proměnných.[37]
¨

Vzhledem k výše uvedenému jsme na místo ruční kompilace BN využili dedikovaný software Netica[38], který umožňuje nejen navrhovat BN, ale i je naučit podmíněné pravděpodobnosti ze souboru dat, a v neposlední řadě umožňuje testovat predikční validitu vaší sítě.

Obě z posledních dvou možností byly využity, kde jsme nejdříve využily trénovací data, aby získal model základní parametry o dopadech metadata na vybrání či nevybrání dostatku kapitálu. Topologie vygenerovaného BN je zobrazena na **Obrázek 34**, a má hvězdicový charakter. Vztahy mezi jednotlivými uzli se řídí právě CPT jak bylo pospáno výše za předpokladu přímého vztahu rodič-dcera mezi uzly. V případě strukturovanějších topologii se může místy jednat o omezenější CPT, ale na druhou stranu má každá podmíněná pravděpodobnost přenesený vliv a na další články v síti.

[37] Počet je dán vztahem n*(k+1), kde n je počet rodičovských uzlů a k počet možných stavů uzlu
[38] Netica je software pro vývoj Bayesovských sítí. Dostupný z https://www.norsys.com/

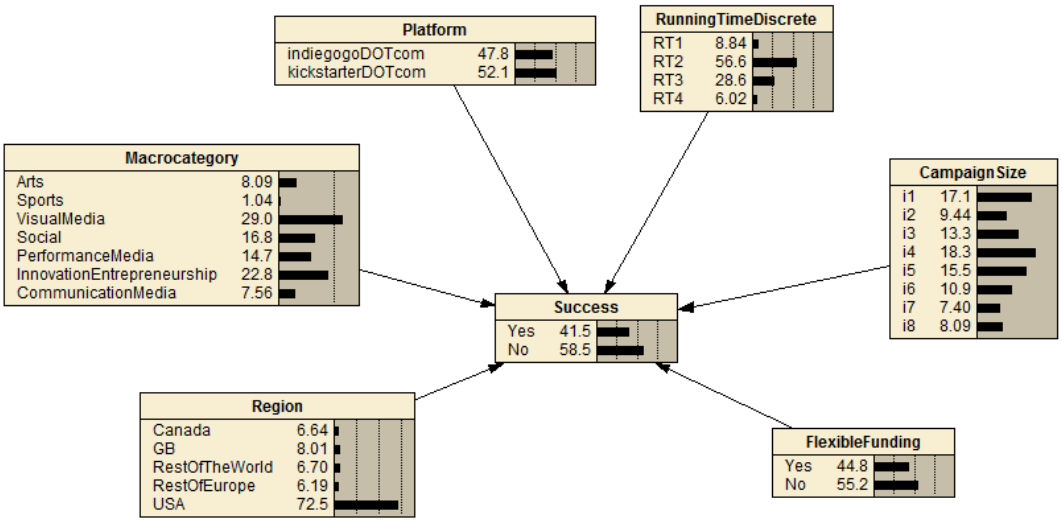

Obrázek 34 BN model metadat crowdfundingových kampaní (vlastní výzkum)

zdroj:Autor

Finální vyhodnocování dat modelem poté spočívá ve vybrání možnosti s větší pravděpodobností předpovězeno v koncovém uzlu.

S plně funkčním BN přišel na řadu základní cíl, který byl při tuto práci vytáčen, a to zjistit prediktivní validitu tohoto modelu.

Test proběhl se sadou dat o 1000 kampaních, které byli také zpracovány Neticou. Chybovost byla 31.3%. V této proporci případů se jednalo o úspěšně zafinancován crowdfundingový záměr, ale model takové kampani předpověděl mylně neúspěch.

Tabulka 5 Predikce BN

zdroj: autor

Yes	No	Actual
104	174	Yes
139	583	No

Souhrnné výsledky testování jsou zobrazené v tabulce. Při přepočtu na úspěšnost v % je patrné, že model velmi úspěšně předpovídá neúspěchy (s 81 % přesností). U úspěchů je to již horší, kde úspěch správně předpovídá jen ve 38 % případů. Zde je nutné podotknout, že pesimistické tendence modelu jsou způsobeny povahou dat, kde velká část crowdfundingových záměrů nevybere dostatek kapitálu. Celková přesnost BN je 68.7 %.

Také jsme zkoumali několik vstupních předpokladů. Jestli je data podporují, či nikoli. Jak se ukazuje, méně ambiciózní cíle mají vyšší úspěšnost. To nicméně nemůže být považováno za překvapivý závěr. Na druhou stranu se ukázalo, že financování “všechno nebo nic” také zlepšuje šance na úspěch projektu. Data také podporují očekávání, že kratší kampaně dopadají lépe.

4.4 Benchmark – Logstická regrese

Pro ověření robustnosti modelu byla následně otestována přesnost BN oproti logistické regresi a tzv. naive walk, což srovnání oproti vlastnímu pravděpodobnostnímu rozdělení dat. Druhý ze jmenovaných postupů vychází z faktu, že díky 72.25% fail ratu kampaní v datasetu, je toto minimální přesnost, když je předpoklad člověka, že žádná kampaň nikdy nevybere dost peněz. Z tohoto důvodu bude ověřeno jak množství „true positives“ oproti logistické regresi, což by mohlo lépe udávat přidanou hodnotu než celková přesnost. Intepretaci bude věnován prostor závěrečné části práce. Za druhé bude ověřena metodika o přidané hodnotě informací, abychom zjistili, jestli je opravdu lepší se odklonit od bazální pravděpodobnosti (odhad podle distribuce, bez korekce).

Logistická regrese je speciální případ vícenásobné regrese, kde nabývá závislá proměnná je binárních hodnot, založených na kauzálním vztahu s několika nezávislými proměnnými. Vyhodnocování probíhá podobně jako u BN, kde je závisle proměnné přiřazena pravděpodobnost nabytí konkrétního stavu. V tomto případě 1 nebo 0, pro předpověď úspěšné, respektive neúspěšné crowdfundingové kampaně. Rozhodnutí je založeno na hraniční hodnotě, zpravidla 0.5, která určuje, od jaké pravděpodobnosti se má model rozhrnout pro jaký závěr. Hodnota 0.5 je standardní, ale pro aplikace, kde si s sebou jedna z variant nese významné riziko, je možné chování upravit. Medicína je jedním z takových odvětví, kde 50% jistota vhodnosti invasivního zákroku, či dalších rozhodnutí, nemusí být dostačující.

Logistická regrese se vyjadřuje následujícím vztahem, pro případ s více prediktory.

$$L = \ln\frac{\pi}{1-\pi} = \alpha + \sum \beta_i X_i$$

$$\pi = P(Y|X_i = x_i) = \frac{e^{\alpha+\sum \beta_i X_i}}{1+ e^{\alpha+\sum \beta_i X_i}}$$

Kde

- L je logti závyslé proměné
- Π pravděpodobnost žádoucího výsledku závysle proměně
- α, β jsou regresní koeficienty prediktorů
- X prediktory (nezívysle rpoměné)
- e základ přirozeného logaritmu.

(Peng, Lee, & Ingersoll, 2002)

Rovnice 15 Logistický Regrese a)

Rovnice 16 Logistický regrese b)

Logistická regrese má jisté další požadavky na vstupní data, takže je nutné dále zpracovat data. Model nepracuje s jinými než numerickými vstupy, což vyžaduje převod kategorických proměnných (textu) na číselné pomocí dummy kódování. V tomto kroku je každý prediktor nahrazen k-1 nezávislými binárními proměnnými, kde k představě počet možných stavů prediktoru. Jeden vynechaný stav slouží vždy jen jako stav referenční.

Vzhledem k výpočetním omezením dostupné technologie byly dummu kódovány i diskretizované parametry finančního cíle.

Po zpracování kompletního dummy kódování jsme vygenerovali rovnici logistické regresy, včetně korelačních koeficientů, za pomoci statistického doplňku MS Excelu a aplikace trénovacího setu dat.[39] Výsledný vztah je dán níže.

$$L = -1.266 - 0.023\beta_1 + 0.042\beta_2 - 0.905\beta_3 + 0.279\beta_4 + 0.277\beta_5 + 0.406\beta_6 + 0.216\beta_7 - 0.809\beta_8 - 0.578\beta_9 - 0.457\beta_{10} - 1.147\beta_{11} - 0.943\beta_{12} - 0.646\beta_{13} + 2.445\beta_{14} + 2.229\beta_{15} + 1.986\beta_{16} + 1.795\beta_{17} + 1.724\beta_{18} + 1.395\beta_{19} + 1.129\beta_{20}$$

Kde

- β je regresní koeficient každého z prediktorů.

Rovnice 17 Řešená rovnice logistické regrese pro potřeby výzkumu této práce

Výsledná pravděpodobnost nabití některého z možných stavů byla následně spočítána **rovnice 16.**

Sestavení finálního regresního modelu následoval test s testovací sadou dat, který stejně jako u BN vygeneroval matici správnosti binárních prognóz na binárním setu alternativ,

Tabulka 6 Logistická regrese výsledky

zdroj: autor

	Success Forecast (% of forecast)	Failure Forecast (% of forecast)
Success	63 (23 %)	53 (7 %)
Failure	215 (77 %)	669 (93 %)

Jak je z výsledků patrné, logistická regrese je náchylnější na jednostrannost zdroje dat ještě o něco více než BN. Incidence správně identifikovaných úspěchů je zde jen 23 %, ale celková přesnost modelu přesahuje 73 %, díky inherentní skepsi. Jak bylo uvedeno výše, vzhledem k povaze dat je předpoklad selhání ve 100 % případů značně přesný co se celkového výkonu prognózy týká.

Vzhledem ke klesající četnosti správně identifikovaných úspěchů byl na regresi aplikován BIR test (Bayesian Infroation Reward test). Jedná se o zkoušku jistoty modelu, která by měla napovědět, jestli je poskytována nějaká přidaná hodnota při využití výše sestavené regrese.

[39] Real Statistics Resoruce Pack for MS Excel available at http://www.real-statistics.com

$$I^{+} = 1 - \frac{log\ p}{log\ p'}\ \ (for\ correct\ classification)$$
$$I^{-} = 1 - \frac{1-log\ p}{1-log\ p'}\ \ (for\ correct\ classification)$$

Kde

- I je odměna za správnou klasifikaci
- p je odhadnutá pravděpodobnost závěru modelem (regresí)
- p' je základní pravděpodobnost, jak dána rozdělením zkoumaných dat

(Hope, Korb, Nicholson, & Twardy, 2008)

Rovnice 18 Bayesian Information Reward – correct classification

Rovnice 19 Bayesian Information Reward – incorrect classification

Test popsaný **rovnicí 18** a **rovnicí 19** podává zprávu o míře jistoty modelu při určování výsledků, ale ignoruje finální rozhodnutí jako takové. Vyjma zohlednění jeho váhy. Výkon modelu je tedy trestán především za špatnou prognózu s vysokou mírou jistoty. Výpočtem jsme dostali hodnotu BIR=∑I=83.326, která je větší než 0. Tudíž by logistický regrese měla být přesnější neznáhodní odhad se základní pravděpodobností.

4.5 Diskuse

Po důkladné analýze obou modelů se ukazuje, že jejich absolutní přesnost je srovnatelná. Regrese sice překonává BN v souhrnné přesnosti o 4.5 %, ale to je dáno inherentním pesimismem na kterém byly modely stavěny vzhledem k povaze zkoumané problematiky.

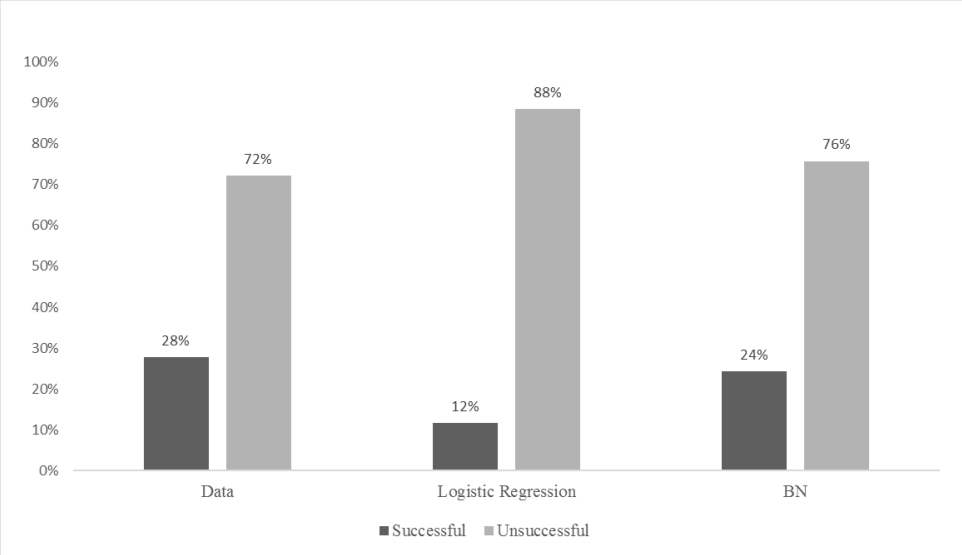

Obrázek 35 Konservativnost dat a analytických modelů

Zdroj: Autor

Vzhledem k podobnému trendu napříč modely, věřím, že ukazatel správně prognózovaných úspěchů je vhodnější metrika pro analýzu získaných poznatků. Tato myšlenka vychází především z možného využití zde prezentovaného výzkumu v praxi. Kdy budou podnikatelé a jiné subjekty mít o trochu lepší představu, jak uspět se svou kampaní na poli odměnového crowdfundingu.

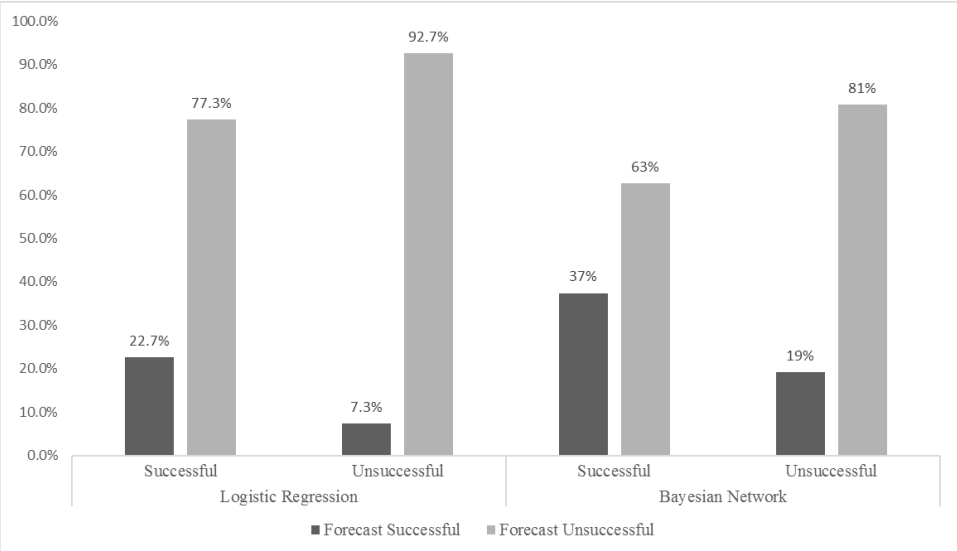

Obrázek 36 Graf zmatečnosti BN a logistické regrese

zdroj: Autor

V identifikaci pozitivních příležitostí BN jasně dominuje nad logistickou regresí. V tomto konkrétním hledisku je rozdíl 15 %., který považuji za poměrně významy.

Netica bohužel neumožňuje jednoduchý výpočet BIR na provedených výpočtech aplikovaných na testovací data. Nemůžeme tedy přímo srovnat kvantifikovanou přidanou hodnotu BN oproti logistické regresi. Nicméně, relativně jednoduše lze předpokládat, že oba modely nabízejí přidanou hodnotu. Jelikož je BN lepší v identifikaci úspěchů, což BIR oceňuje, pokud je to v celém data setu málo četné, tak předpokládám, že BIR zde prezentovaného BN je kladná. Pravděpodobně I vyšší než u regrese, ale zde se jedná o nepodloženou hypotézu.

Závěr

V úvodu práce byl vytyčen cíl propojení začínajících podnikatelů s decentralizovanou společností – davem – přes nástroje na odbourání nejistoty. Nejdříve bylo potřeba předat ucelený pohled na aspekty probírané problematiky.

Z pohledu finančních instrumentů se především jedná o identifikaci tradičních bank jako stále dominantního člena životního cyklu podnikatelů. Nicméně jejich role se z části mění jen na prostředníka, kde se alespoň v Evropě a Spojených státech těšíme pro-podnikatelskému s podporou státních a nadstátních organizací. Dalším stěžejním poznatkem bylo, že tradiční kapitálový investoři ne nutně bojují s postupnou de centralizovaností společnosti, ale místo toho přejímají její nástroje za své. Business angels jsou jedním z největších příkladů měnícího se klimatu, kde dochází k jisté míře demokratizace obchodního vztahu s začínajícími podnikateli. Dnešní specializované platformy umožnují výrazně zefektivnit propojení investorů s podnikateli. Právě business Angeles bývají ti na začátku, jakožto seed investoři. Je však nutné poznamenat, že v celkovém objemu investic stále hrají jen specifickou roli. Nic s univerzální platností. Dále se zkoumané prameny takřka univerzálně shodly na tom, že rodina a přátelé by měli zůstat přesně v tomto vztahu. Jakmile jde o rizikové investice, kterými jsou na počátku podnikání všechny, tak nejsou ve hře je n čas a peníze ale i nenapravitelné škody v okruhu vašich blízkých.

Z pohledu prognózování je stěžení poznatek hlavě připomenutí, že se nejedná o exaktní disciplínu i když má mnohdy exaktní postupy. Nicméně, to neznamená že je nejistotu potřeba plně počítat jako s faktem. Správné počínání má totiž měřitelné pozitivní dopady na přesnost pohledu na budoucnost. Je také potřeba mít na paměti, že budoucnost se dá zkoumat, dá se na ní plánovat nebo se ji můžete pokouše ovlivnit. Každý z těchto procesů má jiné náležitosti a bylo by potřeba je studovat jiných pramenů

Krom stěžejních teoretických poznatků jsme i osvědčil validitu kvantitativních postupů předvídání finanční úspěšnosti. Krom poznatku, že crowdfunding je riziková propozice a neúspěch je v něm četný, tak jsme i explicitně ověřili že informace vycházející z logistické regresní analýzy poskytují přidanou hodnotu. Jelikož Bayesova síť v některých kritériích fungoval lépe, lze s klidným svědomím říci, že jsme splnili náš vymezený cíl. Poskytnout nástroj který snižuje míru nejistoty pro podnikatele v dnešní částečně decentralizované společnosti, kde crowdfunding nabývá stále na větším významu.

I navzdory faktu, že se nakonec jednalo jen o vedlejší poznatky a nebylo diskuzi závěrů věnováno tolik času, můžeme říci, že by se podnikatelé, kteří se dají na crowdfunding, měli vyvarovat flexibilnímu financování a volit krátké časové úseky a skromné cíle. Tyto závěry zasluhují další výzkum. Přesně zapadají do některých iterativních inovačních postupů jako lean start-up.

Seznam použité literatury

Administration, U. S. (5. Janury 2019). *Small Business Administration*. Načteno z About the SBA: https://www.sba.gov/about-sba/sba-performance/policy-regulations

AngelList. (1. January 2019). *Syndicates - Guide For Founders - AngelList*. Načteno z AngelList: https://angel.co/syndicates/for-founders#how_it_works

Anrold, C. E., & Harzog, B. (2009). *The Complete Idiot's Guide to Person-to-Person Lending.*

Armstorng, S. J., Green, K., & Graefe, A. (2015). Golden rule of forecasting: Be conservative.

Armstrong, J. S. (1985). *Long-range forecasting: from crystal ball to computer.*

Bachtík, L. (2018). *Právní regulace crowdfundingu v České Republice.* Praha: Univerzita Karlova: Právnická Fakulta.

Barnes, S., & Mattson, J. (2016). Understanding current and future issues in collaborative consumption: A four-stage Delphi study. *Technological Forecasting and Social Change*, 200-211.

Barnett, C. (9. June 2015). *Trends Show Crowdfunding To Surpass VC In 2016*. Načteno z Forbes: https://www.forbes.com/sites/chancebarnett/2015/06/09/trends-show-crowdfunding-to-surpass-vc-in-2016/#a63a36545476

Baron, J. (2008). *Thinking and Deciding.*

Barringer, B., Hess, E. D., Goetz, C. F., Ireland, D., & Moss, W. (2012). *Entrepreneurship Lessons for Success (Collection).* PH Professional Business.

Bdrich, V. (14. November 2018). *Česká investiční platforma Fundlift překročila 250 milionů korun v zafinancovaných kampaních*. Načteno z CzechCrunch: https://www.czechcrunch.cz/2018/11/ceska-investicni-platforma-fundlift-prekrocila-250-milionu-korun-v-zafinancovanych-kampanich/

Belleflamme, P., Lambert, T., & S. A. (2014). Crowdfunding: Tapping the right crowd. *Journal of Business Venturing*, 585-609.

Commision, E. (5. January 2019). *COSME financial instruments*. Načteno z Internal Market, Industry, Entrepreneurship and SMEs: http://ec.europa.eu/growth/access-to-finance/cosme-financial-instruments/

Commission, E. (5. January 2019). *SME Instrument*. Načteno z Horizon 2020: http://ec.europa.eu/programmes/horizon2020/en/h2020-section/sme-instrument

Crunchbase. (8. January 2019). *AngelList | Crunchbase*. Načteno z Crunchbase: https://www.crunchbase.com/organization/angellist#section-overview

Dictionaries, O. (8. 1 2019). *crowdsourcing | Definition of crowdsourcing in English by Oxford Dictionaries*. Načteno z Oxford Dictionaries: en.oxforddictionaries.com/definition/crowdsourcing

Doan, A., Ramakrishnan, R., & Halevy, A. (2011). The practice of crowdsourcing is transforming. *communications of the acm*. doi:10.1145/1924421.1924442

Du, N., Budescu, D., Majorie, S., & Omer, T. (2011). The appeal of vague financial forecasts. *Organizational Behavior and Human Decision Processes*. Načteno z https://www.sciencedirect.com/science/article/pii/S0749597810000889

Elliott, G., Granger, C. W., & Timmermann, A. (2006). *Handbook of Economic Forecasting.*

Elliott, G., Granger, C. W., & Timmermann, A. (2006). *Handbook of Economic Forecasting.*

European Union. (1. 1 2019). *Access to finance*. Načteno z Your Europe - Business: https://europa.eu/youreurope/business/finance-funding/getting-funding/access-finance/index_en.htm

Fraundorf, S., & Benjamin, A. (2013). Knowing the crowd within: Metacognitive limits on combining. *Journal of Memory and Language*. Načteno z https://ac.els-cdn.com/S0749596X1300096X/1-s2.0-S0749596X1300096X-main.pdf?_tid=f2fbe225-

ae67-47db-9af3-4922fd114d93&acdnat=1546945690_f4b608ec2d57bff70bbf25e8d81dfb99
Freedman, D., & Nutting, M. (5. November 2015). *A Brief History of Crowdfunding: Including Rewards, Donation, Debt, and.* Načteno z Freedman and Nutting: https://www.freedman-chicago.com/ec4i/History-of-Crowdfunding.pdf
Fundlift. (1. January 2019). *Jak na to?* Načteno z Fundlift: https://www.fundlift.cz/#/stranka/jak-to-funguje
Fundlift. (1. 9 2019). *O Nás*. Načteno z Fundlift: https://www.fundlift.cz/#/stranka/o-nas
Galton, F. (1907). Vox Populi.
Glantz, M. (2014). *Navigating the Business Loan.*
Gnatzy, T., Warth, J., von der Gracht, H., & Darkow, I.-L. (2011). Validating an innovative real-time Delphi approach - A methodological.
Goodwin, P., Gönül, M., & Önkal, D. (2013). Antecedents and effects of trust in forecasting advice. *International Journal of Forecasting*. Načteno z https://purehost.bath.ac.uk/ws/files/9833724/Goodwin_IJF_2013.pdf
Gordon, T., & Pease, A. (2006). RT Delphi: An efficient, "round-less" almost real time Delphi method.
Green, C. (2011). *Get Financing Now.*
Green, K., & Tashman, L. (2010). Percentage Error: What Denominator?
Gregosn, G. (2014). *Financing New Ventures.*
Haggarty-Weir, C. (8. October 2017). *The Reasoning Behind a Debt/EBITDA Ratio Surge and the Healthcare Industry.* Načteno z Mostly Science: https://mostlyscience.com/2017/10/reasoning-behind-debtebitda-ratio-surge-healthcare-industry/
Hawkley, L. C., & Cacioppo, J. T. (2012). Loneliness and pathways to disease. *Brain, Behavior and Immunity*.
HitHit. (9. 1 2019). *Hithit - Co je Hithit*. Načteno z HitHit: https://www.hithit.com/cs/article/whatIsHithit
Hope, L., Korb, K., Nicholson, A., & Twardy, C. (2008). Decision Support for Clinical Cardiovascular Risk Assessment.
Howe, J. (8. 1 2019). *Crowdsourcing: A Definition*. Načteno z Crowdsourcing: https://crowdsourcing.typepad.com/cs/2006/06/crowdsourcing_a.html
Chase, C. (2006). *Demand-driven forecasting.*
Chase, C. (2013). *Demand-Driven Forecasting: A Structured Approach to Forecasting.*
Chen, X., Zhou, L., & Wan, D. (2016). Group social capital and lending outcomes in the financial credit market: An empirical study of online peer-to-peer lending. *Electronic Commerce Research and Applications*.
Chiu, C.-M., Liang, T.-P., & Truban, E. (2014). What can crowdsourcing do for decision support? *Decision Support Systems*, 40-49.
Investopedia. (1. January 2019). *Debt*. Načteno z Investopedia: https://www.investopedia.com/terms/d/debt.asp
Investopedia. (6. January 2019). *Personal Finance: Credit: Credit Card*. Načteno z Investopedia: https://www.investopedia.com/terms/c/creditcard.asp
Jaeger, B., Sleggers, W. W., Evans, A. M., Stel, M., & van Beest, I. (2018). The effects of facial attractiveness and trustworthiness in online peer-to-peer markets. *Journal of Economyc Psychology*.
Jandová, & Kaplanová. (12. December 2018). *Kniha Temné matky a jejich dcery*. Načteno z HitHit: https://www.hithit.com/cs/project/5687/kniha-temne-matky-a-jejich-dcery
Jia, J., Fan, B., Dai, S., & Ma, Q. (2017). Beauty premium: Event-related potentials evidence of how physical attractiveness matters in online peer-to-peer lending. *Neuroscience Letters*.
Jin, J., Shang, Q., & Qingguo, M. (2019). The role of appearance attractiveness and loan amount in peer-to-peer lending: Evidence from event-related potentials. *Neuroscience Letters*.

Jose, V. R., & Winkler, R. L. (2008). Simple robust averages of forecasts: Some empirical results.
Kahneman, D. (2011). *Thinking Fast and Slow.*
Kiisel, T. (2013). *Getting a Business Loan: Financing Your Main Street Business.*
Krowdster. (17. February 2015). *Does Kickstarter Still "Own" Indiegogo? | Krowdster*. Načteno z Krowdster: https://www.krowdster.co/blog/does-kickstarter-still-own-indiegogo.html
Lawrence, M., Goodwin, P., O'Connor, M., & Önkal, D. (2006). Judgmental forecasting: A review of progress over the last 25years.
Lebraty, J.-F., & Lobre-Lebraty, K. (2013). *Crowdsourcing: One Step Beyond.*
Lichtig, B. (2105). Crowdfunding Success: The Short Story - Analyzing the Mix of Crowdfunded Ventures. *Wharton Research Scholaars*, 121.
Makonnen, R., & Rogers, S. (2014). *Entrepreneurial Finance, Third Edition: Finance and Business Strategies for the Serious Entrepreneur.* McGraw-Hill.
Makridakis, S., & Taleb, N. (2009). Living in a world of low levels of predictability. *International Journal of Forecasting*.
MarketingSalesMedia. (4. July 2015). *Tipněte si, kolik peněz už lidé darovali projektům na HitHit.cz | MarketingSales.cz*. Načteno z MarketingSalesMedia: https://marketingsales.tyden.cz/rubriky/data/tipnete-si-kolik-penez-uz-lide-darovali-projektum-na-hithit-cz_338834.html
Mingfeng, L., Viswanathan, S., & Prabhala, N. R. (2009). Judging Borrowers by the Company They Keep: Social Networks and Adverse Selection in Online Peer-to-Peer Lending.
Mitra, T., & Gilbert, E. (2014). The Language that Gets People to Give: Phrases that Predict Success on Kickstarter. *17th ACM conference on Computer supported cooper-ative work & social computing* (stránky 1-16). Baltimore: Journal of Business Venturing 29,.
Mollick, E. (2014). The Dynamics of Crowdfunding: An Exploratroy Study. *Jouran of Busness Venturing*, 1-16.
Mollick, E. (21. April 2016). *The Unique Value of Crowdfunding Is Not Money - It's Community.* Načteno z Harvard Busienss Review: hbr.org
Molugaram, K., Shah, A., Rao, G., & Davergave, N. (2017). *Statistical Techniques for Transportation Engineering.*
Murari, A., Pisano, F., Vega, J., Cannas, B., Finni, A., Gozáles, S., . . . Grosso, M. (2014). Extensive statistical analysis of ELMs on JET with a carbon wall. *Plasma Physics and Controlled Fusion*. Načteno z https://www.researchgate.net/figure/Q-Q-plot-probability-and-cumulative-density-function-graphs-empirical-in-blue-model-in_fig10_267208395
Organisation, U. N. (2004). *Foresight Methodologies: Training Module 2.* Vienna: UNIDO.
organizations, C. o. (2003). Naresh, Khatri; Templer, K. J.; Budhwar, Pawan. *VISIONóThe Journal of Business Perspective*.
Peng, C. Y., Lee, K. L., & Ingersoll, G. M. (2002). An introduction to logistic refression analysis and reporting. *The jorurnal of educational research,*, 3-13.
Peníze.cz. (17. 1 2019). *Spotřebitelské úvěry srovnání*. Načteno z Peníze.cz: https://www.penize.cz/srovnani/spotrebitelske-uvery
Picardo, E. C. (2014). *Dog Definition | Investopedia:*. Získáno 5. 5 2015, z Investopedia: http://www.investopedia.com/terms/d/dog.asp
Potůček, M. (2006). *Manuál prognostických metod.*
Prošek, D. (2015). *Kvalitativní Prognózování - moudrost davů v praxi.* Praha: ČVUT.
Prpic, J., Shukla, P., Kietzmann, J., & McRathy, I. (2015). How to work a crowd: Developing crowd capital through crowdsourcing. *Business Horizons*.
Ries, E. (2011). *The Lean Startup.*
Ries, E., Vlaskovits, P., & Cooper, B. (2013). *The Lean Entrepreneur: How Visionaries Create Products, Innovate with New Ventures, and Disrupt Markets.*
Rich, J. (2014). *The Crowd Funding Services Handbook: Raising the Money You Need to Fund Your Business, Project, or Invention.*
Rowe, G., & Wright, G. (1999). The Delphi technique as a forecasting tool: issues and analysis.

Rutherford, M. W. (2015). *Strategic Bootstrapping.*
Sanders, N. (2016). *Forecasting Funamentals.*
Seifert, M., & Hadida, A. L. (2012). On the relative importance of linear model and human judge(s) in combined forecasting.
Sglavo, U., Tashman, L., & Gilliand, M. (2016). *Business Forecasting.*
Sharma, J. K. (2006). *Business Statistics, Second Edition.*
Spreadfast. (8. January 2019). *The 2018 Social Audience Guide*. Načteno z Spreadfast: https://www.spredfast.com/social-media-tips/social-media-demographics-current
Surowiecky, J. (2004). *The Wisdom of Crowds.*
Tanjin, A., Khan, F., & Imtiaz, S. (2019). Fault detection and pathway analysis using a dynamic Bayesian network. *Chemical Engineering Science*, 777-790.
Terry, H., Schwartz, D., & Sun, T. (2015). *The Future of Finance: The Socialization of Finance.* Goldman Sachs.
The Business Research Company. (16. May 2018). *The Growing Pharmaceuticals Market: Expert Forecasts and Analysis*. Načteno z MarketResearch.com: https://blog.marketresearch.com/the-growing-pharmaceuticals-market-expert-forecasts-and-analysis
Vul, E., & Pashler, H. (2008). Measuring the crowd within: probabilistic representations. *Psychological Science*(19). doi:10.1111/j.1467-9280.2008.02136.x
Weinschenk, S. (2013). *How to Get People to Do Stuff: Master the art and science of persuasion and motivation.*
Weisstein, E. W. (16. January 2019). *Central Limit Theorem*. Načteno z MathWorld--A Wolfram Web Resources: http://mathworld.wolfram.com/CentralLimitTheorem.html
Ypsilanti, A., Lazuras, L., Powell, P., & Overon, P. (2019). Self-disgust as a potential mechanism explaining the association betweenloneliness and depression. *Journal of Affective Disorders*.
Zapranis, A., & Alexandridis, A. (2014). *Wavelet Neural Networks: With Applications in Financial Engineering, Chaos, and Classification.*
Zeng, Z., Jiang, X., & Neapolitan, R. (2016). Discovering causal interactions using Bayesian network scoring and information gain. *BMC Bioinformatics*.
Zimmermann, T. W., & Menzies, T. (2016). *Perspectives on Data Science for Software Engineering.*

Seznam obrázků

Obrázek 1 Podíl externích zdrojů financování 7
Obrázek 2 Způsoby financování vztažené k životnímu cyklu podniku 7
Obrázek 3 5C pro posuzování žadatele o bankovní úvěr 11
Obrázek 4 Imact investment instituce 13
Obrázek 5 Schéma fungování evropských fondů 14
Obrázek 6 Struktura instrumentu SME 15
Obrázek 7 Klíčové aktivity nového podniku 18
Obrázek 8 Struktura Amazon Mechanical Turk/ 21
Obrázek 9 Růst crwodfundingu, angel investmentu a venture captial investmentu 22
Obrázek 10 Demografické dělení kapitálové struktury jednotlivců 23
Obrázek 11 Demografické rozdělení tendencí invetovat pomocí crowdfundingu 23
Obrázek 12 Proporcionální zobrazení úspěšných a nespěšných projektů dle platformy 24
Obrázek 13 Dílčí dělení crowdfundingu 25
Obrázek 14 Možná struktura odměn crowdfundingové kampaně 26
Obrázek 15 Proces investičního crowdfundingu z pohledu podnikatele [na platformě Fundlift] ... 29
Obrázek 16 Proces investičního crowdfundingu z pohledu investora [na platformě Fundlift] 29
Obrázek 17 Plánování, Prognózování a řízení poptávky 31
Obrázek 18 Vějířový graf 33
Obrázek 19 Rozdělení hustoty pravděpodobností 34
Obrázek 20 Rozdělení hustoty pravděpodobnosti a kumulativní hustota pravděpodobnosti 34
Obrázek 21 Kategorizace prognostických metod 35
Obrázek 22 Dílčí členění prognostických metod 36
Obrázek 23 Lineární regrese 39
Obrázek 24 Bousselton Network 41
Obrázek 25 Matice prognostických metod a produktové segmentace z hlediska portfolio managementu 42
Obrázek 26 Agregace hodnot MSE pro iterované odhady jednotlivce 43
Obrázek 27 Obecné schéma metody delph 45
Obrázek 28 Konkrétní implementace iteračních kroků metody delphi 46
Obrázek 29 Získávání a příprava dat jako vstupu do analytického modelu 51
Obrázek 30 BN model metadat crowdfundingových kampaní (vlastní výzkum) 52
Obrázek 31 Diskretizace BN – Kategorie 54
Obrázek 32 Graf diskreditované distribuce Finančních cílů a zobrazení exponenciálního růstu intervalů 55
Obrázek 33 CPT BN aplikovaného na crowdfunding (vlastní výzkum) 57
Obrázek 34 BN model metadat crowdfundingových kampaní (vlastní výzkum) 58
Obrázek 35 Konservativnost dat a analytických modelů 62
Obrázek 36 Graf zmatečnosti BN a logistické regrese 62

Seznam tabulek

Tabulka 1 Rozdíly ve formulaci PE jako A-F oproti F-A 48
Tabulka 2 Diskretizace BN - Délka Kampaně 53
Tabulka 3 Diskretizace BN – Geografie 54
Tabulka 4 Diskretizace BN - Finanční Cíl 55
Tabulka 5 Predikce BN 58
Tabulka 6 Logistická regrese výsledky 60

Seznam rovnic

Rovnice 1 Klouzavý průměr 37
Rovnice 2 Trimmed mean 37
Rovnice 3 Winsorized mean 37
Rovnice 4 Exponential smoothing 37
Rovnice 5 Lineární regrese 38
Rovnice 6 Vícenásobná regrese 39
Rovnice 7 Prognostická chyba A-F 48
Rovnice 8 Prognostický Chyba F-A 48
Rovnice 9 Relativní chyba (F-A) 48
Rovnice 10 Relativní chyba (A-F) 48
Rovnice 11 MAPE 48
Rovnice 12 sMAPE 49
Rovnice 13 Podmíněná pravděpodobnost 56
Rovnice 14 Podmíněná pravděpodobnost, kde P(X)=1 56
Rovnice 15 Logistický Regrese a) 59
Rovnice 16 Logistický regrese b) 59
Rovnice 17 Řešená rovnice logistické regrese pro potřeby výzkumu této práce 60
Rovnice 18 Bayesian Information Reward – correct classification 61
Rovnice 19 Bayesian Information Reward – incorrect classification 61

Příloha 1: Kontrolní seznam zlatého pravidla prognózování

Zdroj: (Armstorng, et al., 2015)

Exhibit: Golden Rule Checklist
(With evidence on percentage error reduction)

Guideline	*Done or N/A (✓ or ×)*	*% error reduction*
1. Problem formulation		
1.1. Obtain and use all knowledge		
1.1.1. Obtain all relevant information and sufficient understanding	☐	
1.1.2. Decompose the problem to best use knowledge and judgment	☐	(27–51)
1.1.3. Use evidence-based forecasting methods validated for the situation	☐	(88)
1.2. Avoid bias		
1.2.1. Specify multiple hypotheses or conceal the purpose of the forecast	☐	
1.2.2. Obtain signed ethics statements before and after forecasting	☐	
1.2.3. Structure adjustments for important knowledge outside the model	☐	
1.3. Provide full disclosure to encourage independent audits and replications	☐	
2. Judgmental methods		
2.1. Avoid unaided judgment	☐	
2.2. Frame questions in various ways	☐	
2.3. Combine independent forecasts from heterogeneous experts	☐	(12)
2.4. Obtain reasons for forecasts	☐	
2.5. Ask forecaster why the forecast might be wrong, then to consider revising	☐	
2.6. Use judgmental bootstrapping	☐	(73*)
2.7. Use structured analogies	☐	(39)
3. Extrapolation methods		
3.1. Use all valid and reliable data	☐	
3.2. Decompose by causal forces	☐	(50)
3.3. Damp trend forecasts if the…		
3.3.1. Situation is uncertain or unstable	☐	(5)
3.3.2. Forecast time horizon is longer than the historical series	☐	
3.3.3. Trend goes outside the range of the previous data	☐	
3.3.4. Short- and long-term trend directions are inconsistent	☐	
3.3.5. Series are contrary (trend is inconsistent with causal forces)	☐	(17–43)
3.4. Damp seasonal factors	☐	(2 -20)
4. Causal methods		
4.1. Use prior knowledge to select variables and estimate effects	☐	(20)
4.2. Damp estimated weights	☐	(4)
4.3. Use diverse information, data, and models	☐	(30-39)
4.4. Use all important variables	☐	(48)
5. Combine forecasts from validated methods and diverse data	☐	(<=50)

*More accurate in percent of tests

Human brains are not adapted to solve complex problems with many variables. Think of operating a nuclear power generation plant. For such tasks, checklists are vital. For a review

Prohlášení k použitým citacím

Citace v textu práce převážně nenesou informaci, z jakých stránek daného pramenu byli informace převzaty. Důvodem pro tuto neúplnost je využití digitálního repositáře komerční 3. strany, a zde dostupné dokumenty neobsahovali očíslování stránek.

Tímto prohlašuji, že všechny citace požité v práci odpovídají svým pramenům, a v případě potřeby bude možné doložit tuto skutečnost včetně dohledání patřičné kapitoly a textu ve zdrojovém dokumentu,

Evidence výpůjček

Prohlášení:
Dávám svolení k půjčování této diplomové práce. Uživatel potvrzuje svým podpisem, že bude tuto práci řádně citovat v seznamu použité literatury.

Jméno a příjmení Daniel Prošek
V Praze dne: 17. 01. 2019 Podpis:

Jméno	**Oddělení/ Pracoviště**	**Datum**	**Podpis**