

**EKONOMICKÁ UNIVERZITA V BRATISLAVE
PODNIKOVĽHOSPODÁRSKA FAKULTA
SO SÍDLOM V KOŠICIACH**

Evidenčné číslo: 107003/D/2023/36069194041415684

**ÚLOHA UPISOVATEĽOV NA PRIMÁRNOM
DLHOPISOVOM TRHU**

Dizertačná práca

**EKONOMICKÁ UNIVERZITA V BRATISLAVE
PODNIKOVOHOSPODÁRSKA FAKULTA
SO SÍDLOM V KOŠICIACH**

**ÚLOHA UPISOVATEĽOV NA PRIMÁRNYM
DLHOPISOVOM TRHU**

Dizertačná práca

Študijný program:	ekonomika a manažment podniku
Študijný odbor:	ekonómia a manažment
Školiace pracovisko:	katedra finančného riadenia podniku
Školiteľ záverečnej práce:	doc. Ing. Michal Tkáč, PhD., MBA

Košice 2023

Ing. Jakub Sieber

Zadanie záverečnej práce (vo vytlačenej verzii nahradit' stranou z AIS-u).

Čestné vyhlásenie

Čestne vyhlasujem, že záverečnú prácu som vypracoval samostatne a že som uviedol všetku použitú literatúru.

Dátum: 31.05.2023

.....

Jakub Sieber

Podakovanie

Touto cestou by som sa rád poďakoval môjmu školiteľovi doc. Ing. Michalovi Tkáčovi, PhD., MBA, za cenné rady a smerovanie pri písaní dizertačnej práce.

ABSTRAKT

SIEBER, Jakub: Úloha upisovateľov na primárnom dlhopisovom trhu - Ekonomická univerzita v Bratislave. Podnikovohospodárska fakulta so sídlom v Košiciach; Katedra finančného riadenia podniku. – Vedúci záverečnej práce: doc. Ing. Michal Tkáč, PhD., MBA – Košice: PHF EU, 2023, počet strán 126.

Cieľom dizertačnej práce je analyzovať úlohu upisovateľov na primárnom dlhopisovom trhu. Práca je rozdelená do piatich kapitol. Obsahuje dva obrázky, dvanásť tabuliek, dvadsaťštyri grafov a jednu prílohu. Prvá kapitola je venovaná teoretickým východiskám a pojmom, ktoré vecne súvisia s dlhopismi. Hlavná pozornosť je venovaná prehľadu literatúry, ktorá súvisí funkciami upisovateľov, podrobne je opísaný proces emisie a jeho jednotlivé súčasti. V ďalšej kapitole sa charakterizuje hlavný cieľ a čiastkové ciele práce. Následne je v tretej kapitole charakterizovaná metodika a postupy práce. Štvrtá kapitola sa zaoberá prezentáciou výsledkov dosiahnutých pri skúmaní úloh upisovateľov na primárnom dlhopisovom trhu. Kde je skúmaný vplyv parametrov emisie na výšku hrubého spreadu upisovateľa. Následne je vytvorený klasifikačný strom, ktorý klasifikuje výšku hrubého spreadu do kvartilov na základe jednotlivých parametrov emisie. Pozornosť je venovaná aj fenoménu preupísanosti, resp. podhodnoteniu emisie a jej skúmaniu jej vzťahov s upisovateľmi. Piata kapitola sa venuje diskusii o dosiahnutých výsledkoch, rovnako tak formuluje odporúčania pre prax, vedecké prínosy a smerovanie ďalšieho výskumu.

Výsledkom riešenia danej problematiky je charakteristika upisovateľov na základe ich reputácie, rovnako ako aj súbor definovaných pravidiel za účelom zníženia nákladov pre podnik pri emisii dlhopisov.

Kľúčové slová:

dlhopis, primárny trh, upisovateľ

ABSTRACT

SIEBER, Jakub: The role of underwriters in the primary bond market – University of Economics in Bratislava. Faculty of Business with seat in Košice; Department of Financial Management. – Supervisor of the thesis: Assoc. prof., Ing. Michal Tkáč, PhD., MBA. – Košice: PHF EU, 2023, 126 pages.

The objective of the thesis is to analyse the role of underwriters in the primary bond market. The thesis is divided into five chapters. It contains two figures, twelve tables, twenty-four graphs and one appendix. The first chapter is devoted to theoretical background and concepts that are materially related to bonds. The main attention is given to a review of the literature related to the functions of underwriters, the underwriting process and its different components are described in detail. The next chapter characterizes the main objective and sub-objectives of the thesis. Subsequently, the third chapter characterizes the methodology and procedures of the thesis. The fourth chapter deals with the presentation of the results obtained by examining the roles of underwriters in the primary bond market. Where the effect of issue parameters on the size of the gross underwriter spread is examined. Subsequently, a classification tree is constructed which classifies the amount of gross spread into quartiles based on the different parameters of the issue. Attention is also paid to the phenomenon of over-underwriting or under-underwriting of an issue and its examination of its relationship with underwriters. The fifth chapter discusses the results obtained, as well as formulates recommendations for practice, scientific contributions, and directions for further research.

As a result of addressing the given issue, the characterization of underwriters based on their reputation is presented, as well as a set of defined rules in order to reduce the costs for the company when issuing bonds.

Keywords:

bond, primary market, underwriter

OBSAH

Úvod	11
1 Súčasný stav riešenej problematiky doma a v zahraničí.....	12
1.1 <i>Definícia dlhopisu a jeho stručný vývoj.....</i>	12
1.1.1 Rozdelenie dlhopisov podľa sektora	13
1.1.2 Zabezpečenie, splácanie a výnosy z dlhopisov	14
1.2 <i>Primárny dlhopisový trh.....</i>	15
1.3 <i>Upisovateľ dlhopisu.....</i>	16
1.3.1 Funkcie upisovateľov.....	19
1.3.2 Komerčné banky ako upisovateľ dlhopisov	23
1.3.3 Stanovenie ceny emitovaného aktíva	25
1.4 <i>Podhodnotenie emisie.....</i>	27
1.4.1 Spread upisovateľa – hrubý spread	29
1.4.2 Informačná asymetria.....	33
1.5 <i>Certifikácia dlhopisov</i>	35
1.5.1 Rating dlhopisov a ratingové agentúry	36
1.6 <i>Reputácia upisovateľa</i>	38
2 Cieľ práce	41
<i>Zdôvodnenie aktuálnosti stanoveného cieľa práce</i>	42
3 Metodika práce a metódy skúmania	43
3.1 <i>Charakteristika objektu skúmania</i>	43
3.2 <i>Výskumné otázky práce.....</i>	43
3.3 <i>Pracovné postupy</i>	44
3.3.1 Použité matematicko-štatistické metódy.....	45
3.4 <i>Opis skúmanej vzorky.....</i>	46
3.4.1 Vytvorené premenné pre kvantifikáciu reputácie upisovateľov.....	48
3.5 <i>Hodnotenie platnosti predpokladov.....</i>	50
3.5.1 Deskriptívna štatistika analyzovaných vzoriek	50
3.6 <i>Rozhodovacie stromy.....</i>	54
3.6.1 XGBoost regresný strom.....	54
3.6.2 Klasifikačný strom C5.0	58
3.6.3 Rozhodovací strom CHAID.....	59
4 Výsledky práce	62
4.1 <i>Charakteristika vývoja primárneho trhu podnikových dlhopisov.....</i>	62
4.2 <i>Testovanie vzťahov medzi parametrami emisie a hrubým spreadom</i>	67

4.2.1	Vybrané základné parametre emisie vo vzťahu k hrubému spreadu.....	67
4.2.2	Vybrané parametre upisovateľa emisie vo vzťahu k hrubému spreadu	71
4.3	<i>Analýza vzťahov hrubého spreadu s využitím metód strojového učenia</i>	75
4.3.1	Testovanie vzťahu medzi hrubým spreadom a základnými parametrami emisie.....	76
4.3.2	Testovanie vzťahu medzi hrubým spreadom a parametrov súvisiacich s upisovateľom	79
4.3.3	Testovanie vzťahu hrubého spreadu a kombinácie základných parametrov a parametrov súvisiacich s upisovateľom dlhopisu	84
4.3.4	Testovanie vzťahu hrubého spreadu a parametrov emisie pri definovaných externých faktoroch	85
4.3.5	Klasifikácia výšky hrubého spreadu na základe parametrov	89
4.4	<i>Analýza hrubého spreadu, preupísanosti a upisovateľov</i>	92
4.4.1	Testovanie vzťahu medzi hrubým spreadom a mierou preupísanosti	92
4.4.2	Klasifikácia miery preupísanosti emisie	94
5	Diskusia	101
5.1	<i>Prínosy a odporúčania pre prax</i>	105
5.2	<i>Vedecké prínosy a smerovanie ďalšieho výskumu</i>	107
	Záver	110
	Bibliografické zdroje	112
	Zoznam príloh	126

Zoznam ilustrácií a zoznam tabuliek

Obrázok 1 Proces upisovania podnikového dlhopisu	20
Obrázok 2 Vzťah medzi hrubým spreadom a objemom emisie	31
Tabuľka 1 Opisná štatistika základnej skúmanej vzorky údajov.....	51
Tabuľka 2 Opisná štatistika závislej premennej – Hrubý spread upisovateľa.....	52
Tabuľka 3 Kolmogorov-Smirnovov test rozdelenia závislej premennej	53
Tabuľka 4 Ročné objemy emisií v mld. Amerických dolárov na primárnom dlhopisovom trhu podnikových dlhopisov a medián hodnoty hrubého spreadu(%) rankingu.....	63
Tabuľka 5 Spearmanov korelačný koeficient – vzťah Hrubý spread a Rating.....	71
Tabuľka 6 Hodnotenie predikčnej schopnosti modelu na základe základných parametrov	77
Tabuľka 7 Hodnotenie predikčnej schopnosti modelu na základe parametrov súvisiacich s upisovateľom emisie	80
Tabuľka 8 Hodnotenie predikčnej schopnosti modelu: kombinované parametre	84
Tabuľka 9 Hodnotenie predikčnej schopnosti modelu: kombinované parametre a definované externé faktory	86
Tabuľka 10 Najvýznamnejšie parametre vo výsledných modeloch	88
Tabuľka 11 Presnosť klasifikácie v závislosti od triedenia hrubého spreadu a metódy	89
Tabuľka 12 Presnosť klasifikácie v závislosti od podvzorky a použitej metódy	95
Graf 1 Histogram rozdelenia hrubého spreadu upisovateľa	53
Graf 2 Podiel jednotlivých sektorov emisie na agregátnom primárnom trhu dlhopisov	62
Graf 3 Paretova analýza agregovaného objemu emisií a regiónov v sledovanom období ..	64
Graf 4 Paretova analýza objemu emisií a emitentov podľa odvetvia priemyslu	65
Graf 5 Paretova analýza objemu emisií a emitentov podľa odvetvia priemyslu	66
Graf 6 Box plot analýza hrubého spreadu a meny emisie	68
Graf 7 Box plot analýza regiónu emisie a hrubého spreadu	69

Graf 8 Box plot analýza ratingového ohodnotenia Moodys a hrubého spreadu.....	70
Graf 9 Box plot analýza hodnoty reoffer ceny a hrubého spreadu	72
Graf 10 Box plot analýza hrubého spreadu a postavenia upisovateľa (ročný objem)	73
Graf 11 Box plot analýza hrubého spreadu a medzročnej zmeny postavenia syndikátu.....	74
Graf 12 Box plot analýza hrubého spreadu a preupísanosti emisie	75
Graf 13 Priemerná absolútna hodnota základných parametrov: XGBoost.....	77
Graf 14 SHAP hodnoty pre základné parametre dlhopisov	79
Graf 15 Priemerná absolútna hodnota parametrov súvisiacich s upisovateľom: XGBoost.	81
Graf 16 SHAP hodnoty pre parametre dlhopisov súvisiacich s upisovateľom	82
Graf 17 Klasifikačný strom C5.0 pre výšku hrubého spreadu: Počiatočný uzol.....	90
Graf 18 Klasifikačný strom C5.0 pre výšku hrubého spreadu: pokračovanie	91
Graf 19 Box plot analýza hrubého spreadu a tried miery preupísanosti.....	93
Graf 20 Rozhodovací strom: predikcia miery preupísanosti	94
Graf 21 Klasifikačný strom C5.0 pre preupísanosť: Počiatočný uzol	96
Graf 22 Klasifikačný strom C5.0 pre preupísanosť: Uzol 21	97
Graf 23 Klasifikačný strom C5.0 pre preupísanosť: Uzol 21 (pokračovanie).....	98
Graf 24 Klasifikačný strom C5.0 pre preupísanosť: Uzol 21 (pokračovanie).....	99

Úvod

Výber dlhopisov ako nástroja pre získanie finančných prostriedkov v podnikovej sfére patrí k častým a najmä dôležitým rozhodnutiam manažmentu podniku. Rozhodnutie o získaní dodatočného cudzieho kapitálu je kľúčovou otázkou pri riešení manažérskych rozhodnutí v podnikoch, napríklad v súvislosti s investíciami, vývojom, konkurencieschopnosťou a výkonnosťou podniku. Emisia dlhopisov predstavuje jednu z dostupných alternatív na dosiahnutie spomínaných cieľov. S procesom emisie sú však spojené aktivity, ktoré vykonávajú finančné inštitúcie, ktoré tu emisiu sprostredkovávajú nazývané upisovatelia. Práca je zameraná na analýzu úlohy upisovateľov na primárnom dlhopisovom trhu. Na základe vzorky prvotných verejných ponúk dlhopisov, ktoré sa uskutočnili v rozmedzí rokov 2012 až 2021 práca vysvetľuje, aký vplyv na úspešnosť alebo parametre jednotlivých emisií má výber upisovateľa alebo syndikátu upisovateľov a to v prípade ak sa pozeráme na jeho reputáciu.

Dizertačná práca je rozdelená na päť častí. Úvodná časť práce sa venuje skúmaniu súčasného stavu riešenej problematiky doma a v zahraničí. Pojednáva o teoretických východiskách súvisiacich s dlhopismi a ich náležitosťami. Teoretická časť práce sa zaoberá súčasnými zisteniami pri výskume týkajúcom sa úlohy upisovateľov na primárnom trhu dlhopisov, pričom významná časť prvej kapitoly je venovaná fenoménu podhodnotenia emisie. V nadväznosti na to sú vymedzené pojmy ako hrubý spread upisovateľa, informačná asymetria, rating a ratingové agentúry a reputácia upisovateľa.

Druhá kapitola práce charakterizuje stanovené ciele a z nich vyplývajúce čiastkové ciele, ktoré boli stanovené pre dizertačnú prácu.

Tretia kapitola popisuje metodiku práce, objekt skúmania, pracovné postupy, použité metódy, opis vzorky a testovanie platnosti predpokladov.

Štvrtá kapitola obsahuje dosiahnuté výsledky výskumu. Prvá časť sa venuje charakteristike primárneho trhu s dlhopismi z pohľadu upisovateľov. V druhej časti sa zameriavame na dôležité výkonnostné parametre emisie akými sú hrubý spread a preupísanosť.

Záverečná kapitola sa venuje diskusii ohľadom dosiahnutých výsledkov práce, formuluje odporúčania pre prax, vedecké prínosy a možnosti ďalšieho smerovania výskumu.

1 Súčasný stav riešenej problematiky doma a v zahraničí

Cieľom prvej kapitoly tejto práce je poskytnúť čitateľovi charakteristiku skúmaného javu ako aj popísať procesy, ktoré súvisia s novou emisiou dlhopisov na primárnom dlhopisovom trhu.

V prvej kapitole práce charakterizujeme pojem dlhopis a jeho základné vlastnosti, pričom nezabudneme ani na stručný opis historického vývoja dlhových cenných papierov. . Pozornosť budeme venovať najmä opísaniu rozdielností dlhopisov v rámci sektorov v ktorom sú emitované a taktiež náležitosti, ktoré dlhopis ako forma dlhového cenného papiera obsahuje. Pri písaní prvej kapitoly vychádzame najmä zo zahraničnej literatúry, keďže trh s dlhopismi nie je na území Slovenskej republiky dosiaľ tak etablovaný ako v iných krajinách (Tvardzík, 2021), aj keď v roku 2022 nastáva nárast obchodovania na sekundárnom trhu, počet nových emisií stagnuje (Bratislavská burza cenných papierov, 2023).

V ďalšej časti práce sa budeme zaoberať vysvetlením primárneho trhu a jeho vlastností, definovaným upisovateľa dlhopisu a jeho funkcií. Jednotlivé funkcie upisovateľa dlhopisu následne opíšeme v podkapitolách, pričom pozornosť sa sústreďí na sumarizáciu zistení z už uskutočnených štúdií v predmetnej oblasti týkajúcej sa najmä podhodnocovania emisií a ich certifikácie, ratingom a ratingovým agentúram a ich úlohe pri emisii. V teoretickej časti práce sa sústreďíme na skúmanie vplyvu a úloh upisovateľov dlhopisov v podnikovej sfére. Z daného dôvodu budeme klásť dôraz v jednotlivých častiach prvej kapitoly najmä na súvislosti s podnikovými dlhopismi.

1.1 Definícia dlhopisu a jeho stručný vývoj

Z hľadiska investora dlhopisy vyjadrujú vzťah medzi dlžníkom a veriteľom, z tohto hľadiska je možné ich nazvať aj ako úverové cenné papiere. Okrem úverového cenného papiera je možné sa stretnúť aj s označením ako dlhový cenný papier alebo obligácia. Podľa právnej úpravy Slovenskej republiky na základe zákona č. 530/1990 Zb. o dlhopisoch možno dlhopis definovať ako *„cenný papier, s ktorým je spojené právo majiteľa požadovať splácanie dlžnej sumy v menovitej hodnote a vyplácanie výnosov z nej k určitému dátumu a povinnosť osoby oprávnenej vydávať dlhopisy (ďalej len emitent) tieto záväzky plniť.“*

Fabozzi a Anson (2007) opisujú dlhopis ako finančný inštrument, ktorý vyjadruje vzťah medzi veriteľom a emitentom, kde emitentovi vyplýva povinnosť splniť záväzky

vychádzajúc z nominálnej hodnoty dlhopisu a z nej plynúceho výnosu k fixne stanovenému dátumu.

Jednu z prvých zmienok o vývoji dlhu, resp. požíčavania na dlh a z toho vyplývajúceho úroku spomínajú Homer a Sylla (2005) a Puga a Trefler (2012) v počiatkoch Mezopotámie, nakoľko sumerské chrámy v skutočnosti fungovali nielen ako miesta bohoslužieb, ale aj ako banky – a tu sa začali úplne prvé rozsiahle systémy pôžičiek a úverov. Ako mestá rástli, simultánne rástla aj zložitosť potrieb ľudí a zmlúv o pôžičkách a tak sa vyvinula myšlienka účtovania úrokov. Striebro v tomto období začalo získavať na popularite, no na rozdiel od dobytku a obilia si prirodzene nezískalo záujem. Ďalší zo spôsobov požíčavania možno nájsť aj v starovekom Grécku, kde obchodníci požíčavali peniaze s tým, že si od dlžníka vyžiadali zábezpeku, najčastejšie vo forme fyzického predmetu alebo majetku dlžníka (Homer a Sylla, 2005), čo funguje obdobným spôsobom ako v dnešnej dobe kolaterál a teda zníženie rizika pre veriteľa.

Pre potreby opisu vývoja dlhopisov do podoby, ktorá je podobná s tou ako ju poznáme dnes, je potrebné spomenúť dve obdobia, ktoré vývoj dlhových cenných papierov podnietili. Ako uvádzajú Puga a Trefler (2012), signifikantnú úlohu v rozvoji zohralo Taliansko v čase stredoveku, konkrétne vznikom prvých bánk, ktoré založil rod Mediciovcov vo Florencii (Ferguson, 2011). Požíčavanie na dlh bolo spôsobom, ako mohli Benátky, Florencia a iné mestské štáty zabezpečiť financovanie objaviteľských ciest, vojnových a dobyvačných výprav. Po tom, ako banky začali poskytovať úvery, bol zdroj dlhopisov veľkou revolúciou pri vzostupe peňazí a ich úlohy vo svetovom hospodárstve (Puga a Trefler, 2012). Ďalšou inováciou, ktorá podporila vznik dlhopisov do dnešnej podoby bolo podľa Fergusona (2011) založenie Anglickej banky (*Bank of England*) v roku 1694. Bolo to práve Britské impérium, ktoré v roku 1749 založilo Konsolidačný fond, odkiaľ pochádza pojem *konsolidačné dlhopisy* – štandardizované dlhopisy britskej vlády, ktorých úlohou bola konsolidácia verejných financií a zníženie dlhu vytvoreného predchádzajúcimi vojnami.

1.1.1 Rozdelenie dlhopisov podľa sektora

V prípade, ak rozlišujeme sektor, v ktorom je daný dlhopis ponúkaný rozlišujeme najčastejšie sektory: *I. podnikových dlhopisov, II. štátnych (vládných) dlhopisov, III. komunálnych dlhopisov, IV. dlhopisov finančných inštitúcií (niekedy označovaných aj skráteno ako finančných), V. multinacionálnych dlhopisov, resp. nadnárodných dlhopisov*

a VI. *agentúrnych dlhopisov*. (SEC, 2021; Európska komisia, 2021) Najväčší objem vydaných dlhopisov sa vyskytuje v podnikovom (korporátnom) sektore. Podľa americkej komisie pre kontrolu cenných papierov (SEC) (2021) je možné podnikové dlhopisy označiť za typ dlhového nástroja. Keď investori nakupujú podnikové dlhopisy, v skutočnosti požičiavajú peniaze firme, ktorá dlhopis vydáva. Výmenou sa spoločnosť zaväzuje zaplatiť úrok z istiny a vo väčšine situácií splatiť istinu, keď dlhopis nadobudne splatnosť. Podobne ako SEC aj Európska komisia (2021) opisuje podnikové dlhopisy, inak označované aj ako korporátne dlhopisy či obligácie, ako dôležitý zdroj financovania pre európske spoločnosti, ktoré môžu príjmy plynúce z predaja dlhopisov použiť na investície do rastu a tvorby pracovných miest. Podnikom tak ponúkajú prístup k alternatívnym a rôznorodejším zdrojom financovania. Dlhopisy finančných inštitúcií predstavujú formu vernostného dlhopisu, alebo inak povedané sú aj druhom poistenia spoločnosti. Primárnou úlohou je zaistenie ochrany organizácií poskytujúcich finančné služby. Dlhopisy finančných inštitúcií poskytujú krytie strát pri podvodných aktivitách, ako je napríklad otváranie falošných klientskych účtov alebo spiach existujúcich účtov (Hunt, 2015; O'Malley, 2015; Medzinárodný Inštitút pre Manažment Rizika, 2021). Multinacionálne dlhopisy predstavujú dlhopisy, ktorých emitentom je viacero štátnych autorít, zoskupenie štátov alebo federálna inštitúcia, príkladom multinacionálnej formy emisie sú napríklad dlhopisy európskej investičnej banky. Agentúrne dlhopisy predstavujú dlhopisy, ktoré sú emitované organizáciou, ktorá je z väčšiny riadená štátnou autoritou alebo ide o kompletne štátny podnik (Levick – Yang, 2017).

1.1.2 Zabezpečenie, splácanie a výnosy z dlhopisov

Základné kritérium, ktoré možno rozlíšiť pri podnikových dlhopisoch sú podľa (Siddhartha, 2011) formy zabezpečenia dlhopisu z pohľadu majetku emitenta. Tie rozlišujeme na: *I. pevné, II. Pohyblivé, III. Kolaterálne ručené dlhopisy (zabezpečené)*. Zabezpečené dlhopisy predstavujú, že dlh, ktorý emitent vytvorí je krytým dlhom. V prípade pevného zabezpečenia sú dlhopisy kryté pevným majetkom. V takomto prípade emitent týmto majetkom disponuje až do termínu splatnosti. V prípade, ak hovoríme o pohyblivom zabezpečení, tak je dlhopis krytý celým majetkom spoločnosti. Z pohľadu investora predstavujú dlhopisy s pevným zabezpečením menšie riziko, ako to je v prípade pohyblivého zabezpečenia. Pri obligáciách zaručených založením vedľajšej istiny sa očakáva, že takéto dlhopisy sú zaručené inými, tzv. záložnými cennými papiermi, ktoré sú v držbe opatrovníka

v prospech investorov (Siddhartha, 2011; Thau, 2010). Delenie dlhopisov podľa zákona č. 530/1990 Zb. o dlhopisoch pre podmienky Slovenskej republiky, ako aj prehľad najčastejších typov dlhopisov používaných v zahraničí, podľa možnosti výnosu z dlhopisov možno nájsť v prílohe, časť A.

1.2 Primárny dlhopisový trh

Primárny trh je miesto, kde sú prvýkrát emitované cenné papiere kapitálového trhu, zatiaľ čo sekundárny trh je miestom, kde investori obchodujú neskôr. Prvotný verejný predaj (*angl. Initial Public Offering*) (IPO), pri ktorej spoločnosť predáva nové cenné papiere a získava všetky výnosy vo forme dodatočného kapitálu, sa nazýva primárna ponuka. Preto sa IPO trh pomerne často označuje ako primárny trh. Protipólom k primárnemu trhu je sekundárny trh. Sekundárny trh možno definovať ako miesto, kde uskutočnené transakcie nezahŕňajú vytváranie nových cenných papierov a externého kapitálu pre emitenta. Sekundárne trhy v takomto prípade neslúžia na financovanie spoločnosti, ale sú skôr trhom pre akcionárov a externých investorov na nákup a predaj sekundárnych cenných papierov. Ceny cenných papierov na primárnych trhoch sú pevné (napr. cena ponuky IPO), zatiaľ čo ceny na sekundárnych trhoch kolíšu s ponukou a dopytom. Podnik, ktorý sa rozhodne realizovať IPO by sa mal taktiež podieľať na procese uvádzania prospektu spolu s upisovateľom, čo napomáha najlepšiemu predaju poskytnutých dlhopisov (Yeoman, 2001).

Primárnym cieľom IPO je navýšenie disponibilného kapitálu – zdrojov, ktoré dokáže emitent získať výmenou za poskytnuté záväzky verejnosti. Ako spomínajú Griffin a kol. (2007) základným predpokladom v odvetví je, že krivka dopytu IPO má negatívny sklon. Ak teda *bookrunner* (*primárny upisovateľ*) nedokáže generovať dostatočný dopyt klientov po IPO, ďalší emitenti môžu považovať upisovateľa za slabého propagátora emisie. Jedným z častých tvrdení je, že upisovatelia pridávajú emisie zvýhodneným inštitucionálnym klientom s tým, že klienti by si kúpili viac cenných papierov daného IPO na sekundárnom trhu. Takáto činnosť sa nazýva tzv. *laddering* v tom zmysle, že môže pomôcť tlačiť ceny na vyššiu úroveň prostredníctvom umelo vytvoreného dopytu. *Laddering* zahŕňa *quid pro quo* (*lat. niečo za niečo*) vzťah medzi upisovateľmi a ich klientmi - investormi. Tento vzťah opisuje, že klienti dostávajú pridelenie akcií IPO s implicitným alebo výslovným porozumením a príslubom, že nakúpia ďalšie podiely na sekundárnom trhu pre predmetnú emisiu. V prípade odstúpenia od spomínaného vzťahu upisovatelia presadzujú tieto údajné dojednania prostredníctvom zadržiavania budúcich pridelení IPO. Krigman a kol. (1999)

zdôrazňujú, že upisovatelia v mnohých prípadoch neocenia majetkové alebo dlhové cenné papiere správne, nakoľko neexistuje žiadny postih za zlé ocenenie IPO. Dôvody, prečo sa tak deje budú rozpracované v podkapitole 1.4., ktorá sa bude venovať podhodnoteniu emisie.

Podľa definície Morricone a kol. (2017) IPO predstavuje kľúčovú udalosť v životnom cykle firiem, ktorá ich umožňuje získať nové finančné prostriedky od externých investorov prostredníctvom emisie nových cenných papierov. Fernando (2021) opisuje podstatu IPO, ako proces ponúkania akcií (záväzkov) súkromnej spoločnosti verejnosti pri novej emisii akcií. Primárnym dôvodom IPO je získať kapitál spoločnosti od verejných investorov. Prechod zo súkromnej na verejnú spoločnosť môže byť pre súkromných investorov dôležitým obdobím na to, aby plne realizovali zisky zo svojej investície, pretože zvyčajne zahŕňa prémiiu pre súčasných súkromných investorov. O'Malley (2015) opisuje primárny trh ako akýkoľvek finančný trh, na ktorom dochádza k prvému predaju finančného nástroja emitenta. Najčastejšie sa v roli hlavného sprostredkovateľa IPO objavujú predovšetkým banky a to najmä investičné banky. Okrem stanovenia predajnej ceny je úloha upisovateľa taktiež dôležitá aj pri procesoch po zahájení IPO, ako je udržiavanie trhového záujmu a informovanosti pre lepšiu stabilitu cien pri prechode na sekundárny trh. Upisovateľ dlhopisov vystupuje v úlohe spojovacieho článku medzi investormi a emitentom, nakoľko dokáže kontrolovať dopyt a ponuku po emitovaných cenných papieroch (Ritter and Welch, 2002). Predaj cenných papierov, pri ktorom sa predávajú cenné papiere v držbe vlastníkov spoločnosti a z ktorých majitelia získavajú výnosy, sa nazýva sekundárna ponuka. IPO sú takmer vždy primárnou ponukou, ale môžu zahŕňať predaj cenných papierov vlastnených súčasnými vlastníkmi (PwC, 2017). Autori Hale a Santos (2006) tvrdia, že trh s dlhopismi je pre podniky dôležitejším zdrojom externých financií ako akciový trh.

1.3 Upisovateľ dlhopisu

V prípade ak určitá entita potrebuje získať dodatočný externý finančný kapitál, jedným zo spôsobom akým to môže vykonať je emisia cenného papieru. Emitent prichádza na trh cenných papierov väčšinou periodicky – a tak sa dá predpokladať, že takýto emitent nedisponuje dostatkom expertných znalostí, know-how, aby dokázal zabezpečiť správne ocenenie a umiestnenie cenných papierov. Autori Papaioanou a Karagozoglu (2017) tvrdia, že emitent dokáže prekonať zmienené nevýhody tým, že si zaistí služby finančnej inštitúcie, ktorá vykonáva asistenčné služby ako je napríklad: ocenenie, marketing, umiestnenie emisie, prevzatie rizika spojeného s uvedením nových cenných papierov na trh. Emitent na oplátku

za získané služby upisovateľa dlhopisu finančne odmení vo forme upisovateľského poplatku (*angl. subscription fee*).

Typická forma IPO pozostáva z mnohonásobného počtu upisovateľov, ktorí vytvoria tzv. syndikát predajcov, kde jeden z upisovateľov slúži ako primárny alebo vedúci upisovateľ (*angl. bookrunner, lead*) (Yasuda, 2005). Označenie *Lead* manažér je možné definovať ako vedúci alebo hlavný upisovateľ novej emisie. Ak existuje viac ako jeden vedúci manažér, označujú sa ako spoloční vedúci manažéri (O'Malley, 2015). Skupina upisovateľov, ktorá je vytváraná pri väčších emisiách sa zvykne označovať ako syndikát. Po zrušení obmedzení vyplývajúceho z účinnosti zákona *Glass-Steagall* sa môžu aj komerčné banky uchádzať o vedúcu pozíciu v upisovaní cenných papierov, ktorú predtým výlučne zaujímali investičné banky. Tieto zmeny zintenzívnili konkurenciu medzi upisovateľmi o zabezpečenie mandátov a právomocí na IPO a viedli k nárastu početných vedúcich upisovateľov (MLU, *angl. Multiple Lead Underwriter*). Ako ukazuje niekoľko nedávnych štúdií (Hu a Ritter, 2007; Jeon a kol. 2015), používanie syndikátov MLU spôsobuje významnú zmenu v tom, ako upisovatelia spravujú svoje ponuky IPO (Bajo a kol. 2016).

Na základe zistení prezentovaných v práci Bajo a kol. (2016) bolo zistené, že IPO, ktoré sú upísané väčším a známejším upisovateľom s centralizovaným vedením sú spojené s väčšími zmenami ceny ponuky za IPO. Spomínané IPO, ktoré boli upísané sa spájajú aj s vyšším ocenením a následnými vyššími výnosmi na sekundárnom trhu. Kľúčovou výhodou syndikátov MLU je, že môžu produkovať ďalšie informácie nad rámec kapacity, ako to je v prípade jednotlivého upisovateľa (SLU, *angl. Single Lead Underwriter*). Napríklad v porovnaní so SLU syndikát MLU povoľuje upisovateľom prideliť dodatočné zdroje počas predbežnej povinnej starostlivosti, čo umožňuje upisovateľom dôsledne preveriť emitenta a presne odhadnúť cenové rozpätie predbežnej ponuky (Hanley a Hoberg, 2010). Corwin a Schultz (2005) tvrdia, že väčší syndikát umožňuje upisovateľom komunikovať so širšou skupinou potenciálnych investorov počas tvorby a zisťovania potenciálneho dopytu po emisii medzi investormi, čo im zároveň umožňuje zhromažďovať viac súkromných informácií od investorov. Okrem toho, vďaka rozšírenej sieti obchodov, môžu MLU šíriť informácie o IPO širšej skupine potenciálnych investorov. Uvedené skutočnosti sú podporené aj tvrdením Bajo a kol. (2016), ktorí argumentujú, že IPO podniku upísaného viacerými vedúcimi upisovateľmi vytvárajú na burze väčší dopyt po emisii. Dané to je aj faktom, že takéto firmy sleduje väčší počet finančných analytikov, čo sa prejavuje aj na existencii väčšieho podielu inštitucionálnych investorov. Cenné papiere, či už majetkové

alebo dlhové, firiem prijatých na burzu viacerými centrálnymi vedúcimi upisovateľmi majú vyššiu likviditu na sekundárnom trhu a lepšie dlhodobé (šesť mesiacov až jeden rok) výnosy po IPO. (Liu a kol., 2014; Bajo a kol., 2016)

V tejto súvislosti je vhodné poukázať na rozdielnosť pojmov *Lead* manažér a *Bookrunner*, na ktorú upozorňuje aj O'Malley (2015), pojem *Bookrunner* možno charakterizovať ako vedúceho manažéra v emisii dlhopisov, ktorý je úplne alebo čiastočne zodpovedný za riadenie zisku alebo straty z predmetnej emisie. *Bookrunner* je vždy vedúci manažér ale vedúci manažér nie je vždy *Bookrunner*. Pri IPO je možné sa stretnúť aj s pojmom pasívny *Bookrunner*, tento pojem predstavuje subjekt bez akejkoľvek úlohy pri organizovaní a distribúcii novej emisie podnikových dlhopisov. Pasívni *Bookrunneri* zvyčajne získajú celý upisovací záväzok plus poplatky a prístup k emisii. Banka ako upisovateľ dlhopisov disponuje informačnou výhodou, nakoľko dokáže vytvoriť dopyt po cenných papieroch rýchlejšie, rovnako tak dokáže čeliť nižšej miere rizika nepredaných cenných papierov a profitovať z nižších hraničných nákladov spojených z marketingom a predajom. Komerčné banky môžu strategicky nastaviť cenu upísania dlhopisov pre emitenta tak, aby sa táto cena rovnala hraničným nákladom spojených s aktivitami uvedenia cenných papierov na trh, za cieľom získať trhovú podiel pri následnom predaji. Na druhej strane, ak dokážu banky svojou informačnou výhodou produkovať pre emitenta vyššie výnosy v budúcnosti, je možné, že sa táto skutočnosť odrazí vo vyšších poplatkoch spojených s upísaním dlhopisov na primárny trh. (Fabozzi a Fabozzi, 2021; O'Malley, 2015)

Upisovatelia zohrávajú kľúčovú úlohu na trhu podnikových dlhopisov (Nagler – Ottonello, 2017). Vo všeobecnosti možno konštatovať, že upisovatelia poskytujú emitentom umiestnenie emisie na trhu a s tým korešpondujúce služby. Medzi jednu z hlavných služieb, ktoré upisovateľ poskytuje je formovanie počiatočnej alokácie dlhopisov medzi investorov. Upisovatelia dlhopisov navyše pôsobia aj ako predajcovia na sekundárnom trhu (Nagler – Ottonello, 2021).

Vo všeobecnosti je možné tvrdiť, že upisovanie nových dlhopisov je súčasťou aktivít, ktoré sa odohrávajú na primárnych kapitálových trhoch. Spoločnosti, ktoré sa angažujú v poskytovaní služieb v spojitosti s upisovaním dlhopisov sa nazývajú investičnými bankami. V skutočnosti však majú investičné banky oveľa širšie portfólio služieb, ako je len upisovanie nových cenných papierov. Najčastejšie služby, ktoré tieto banky ponúkajú sú napríklad: obchodovanie na finančných trhoch, maklérske služby, poradenské služby pre podnikové spoločnosti, správa majetku a pod. V niektorých prípadoch investičné banky

vystupujú aj ako skupina sprostredkovateľov úverov alebo investorov, v takomto prípade je možné hovoriť, že kapitál je poskytnutý syndikátom investičných bánk (Yasuda, 2005). Investičné banky môžu fungovať na báze nezávislej investičnej banky (napríklad Goldman Sachs, Morgan Stanley) alebo ako divízia iných finančných inštitúcií, bánk alebo poisťovacích spoločností (napríklad Merrill Lynch ako súčasť Bank of America) (Papaioanou a Karagozoglu, 2017). Investičná banka tak preberá emisiu cenného papiera buď sama, alebo vytvára syndikát upisovateľov, ktorý je tvorený viacerými investičnými bankami.

1.3.1 Funkcie upisovateľov

Upisovatelia ako sprostredkovateľ v procese navyšovania kapitálu emitenta vykonávajú niekoľko dôležitých funkcií, ktoré pomáhajú získať emitentovi kapitál ponukou cenných papierov: *I. Ohodnotenie a ocenenie, II. Certifikácia, III. Marketing, IV. Distribúcia.* (Papaioanou a Karagozoglu, 2017)

Yasuda (2005) opisuje IPO ako proces, kde emitent, ktorý sa rozhodne pre emisiu dlhopisu si najíma upisovateľa, vo významnej väčšine prípadov banku, ktorá mu za poplatok poskytne dva druhy služieb:

- poistenie nepredaného objemu dlhopisov,
- asistenciu pri dokumentácii, marketingu, oceňovaní a predaji emisie.

Za predpokladu, že emisia dlhopisov nastáva prvýkrát (IPO), je možné predpokladať, že neexistujú predchádzajúce historické informácie, ktoré by slúžili ako ukazovateľ o finančnej kondícii a stabilite emitenta. Upisovateľ dlhopisov uskutoční odborné posúdenie finančného pozadia emitenta za cieľom aby zhromaždil vhodné informácie a dokázal dospieť k dôveryhodnému *ohodnoteniu* emitenta.


Ešte dôležitejšou funkciou ako ohodnotenie emitenta je jeho *ocenenie*. Ocenenie predstavuje proces, v ktorom upisovateľ stanoví ponúkanú cenu (*angl. offer price*), za ktorú dané aktívum bude akceptované investormi.

Pri pohľade na nižšie uvedený obrázok 1 popisujúci priebeh procesu upisovania emisie je možno konštatovať, že celý proces je možno rozdeliť do šiestich základných fáz:

- I. fáza - výber vedúceho upisovateľa (Lead).* V tejto fáze si emitent vyberá investičnú banku, ktorá bude emisiu jeho cenného papiera riadiť. Vo väčšine

prípadoch vedúci upisovateľ emisie formuje syndikát, ktorá ma za úlohu alokovať predmetnú emisiu medzi investorov. O tom, či bude vytvorený syndikát má právo rozhodnúť aj emitent.

II. *fáza – ponuka emisie investorom.* V tejto fáze sa cenný papier predstavuje potenciálnym investorom, indikuje sa prvotný záujem o emisiu, čo je využité v nasledujúcich fázach procesu upisovania, najmä pre stanovenie ceny.



Obrázok 1 Proces upisovania podnikového dlhopisu

Zdroj: Vlastné spracovanie podľa (Nikolova a kol., 2020; Levow.com, 2004)

- III. *fáza – oceňovanie emisie.* Vo fáze oceňovania predmetného podkladového aktíva vychádzajú upisovatelia z poznatkov, ktoré získali v predchádzajúcich fázach pri zisťovaní dopytu a záujmu zo strany investorov. Investori slúžia ako signalizátor potenciálnej predajnej schopnosti upisovaného aktíva. Poznatkom o oceňovaní emisie sa venujeme v neskoršej časti práce (viď. podkapitola 1.3.2).
- IV. *fáza – registrácia a potvrdenie regulátorom.* V tejto fáze upisovateľ úzko spolupracuje s regulátorom príslušného trhu, stanoví cenu a vytvorí prospekt pre daný cenný papier
- V. *fáza – potvrdenie prospektu a podpísanie zmlúv s investormi.* Po schválení náležitostí emisie regulátorom prebieha registrácia u vedúceho upisovateľa (Lead) , zhromažďujú sa potrebné podklady pre IPO a prospekt emisie schválený regulátorom je zaslaný investorom. Vedúci upisovateľ resp. syndikát podpisuje finálnu zmluvu s emitentom.
- VI. *fáza – umiestnenie emisie medzi upisovateľov.* V prípade, ak je IPO realizované syndikátom upisovateľov, v tomto momente preberá zodpovednosť za umiestnenie medzi syndikát vedúci upisovateľ, ktorý prerozdeli celý objem emisie.

Certifikácia predstavuje schopnosť upisovateľa, ktorou dokáže presvedčiť trh o spravodlivosti ponúkanej ceny. Certifikácia je mnohokrát ovplyvnená reputáciou upisovateľa a históriou jeho predchádzajúcich IPO. Keďže príjmy upisovateľov sú závislé od opakovaných obchodov, upisovatelia majú motiváciu udržiavať si povest' dôveryhodných sprostredkovateľov. Budovanie dôveryhodnosti možno opísať ako kapitál reputácie. Čím vyššia je úroveň reputácie, tým je väčšia certifikačná sila upisovateľa. (Anders, Betzer a Limbach, 2014)

Marketingové aktivity upisovateľov v súvislosti s novou emisiou majú podstatu v predstavení nadobudnutých informácií o emitentovi a o emisii ako takej. Upisovatelia majú rozsiahle kontakty a siete inštitucionálnych a retailových klientov, ktorým môžu ponúknuť nové cenné papiere. Podľa tvrdení (Papaioanou a Karagozoglu, 2017), sú inštitucionálni investori vo všeobecnosti uprednostňovaní pred retailovými investormi. Inštitucionálni investori sú uznávaní pre ich poznatky a vedomosti o oceňovaní emisie, ktoré prinášajú do procesu zisťovania cien a taktiež pre ich nákupnú kapacitu. Okrem spomínanej

výhody pri oceňovaní emisie, môžu byť inštitucionálni investori klientmi s pridanou hodnotou aj inými spôsobmi a to napríklad makléorskými a obchodnými činnosťami, ktorými dokážu zjednodušiť proces upisovania inštitúcii sprostredkujúcej emisiu (investičnej banke). Alokácie väčšieho objemu cenných papierov pre inštitúcie taktiež znižujú náklady na umiestnenie emisie, pretože inštitucionálni investori nakupujú vo veľkých množstvách. Upisovatelia majú záujem udržiavať si lojalitu a reputáciu medzi inštitucionálnymi investormi, ktorí môžu byť vďaka svojmu obchodnému modelu a zdrojom periodickými nákupcami nových emisií v rôznych obdobiach. Uskutočnené štúdie ukazujú, že inštitucionálni investori sú uprednostňovaní pre alokáciu kvalitnejších IPO, ktoré majú atraktívne cenové zľavy a vytvárajú lepšie dlhodobé výnosy (Aggarwal, Prabhal a Puri, 2002; Boehmer, Boehmer a Fische, 2006).

Prezentácia emisie a emitenta v spojení sa deje prostredníctvom osobných kontaktov alebo prezentácií v rámci takzvaných IPO roadshow, kde môžu upisovatelia komunikovať dôležité informácie, ktoré pomáhajú investorom získať informácie o novej emisii. Roadshow opisuje O'Malley (2015) ako sériu prezentácií emitenta cenných papierov pre potenciálnych investorov v rôznych finančných centrách. Funkcia *distribúcie* predstavuje kulmináciu ocenenia emisie a marketingových aktivít v celom procese upisovania cenných papierov. Distribúcia okrem samotného procesu predaja cenných papierov zahŕňa aj proces indikácie, akým investorom budú cenné papiere predané. Yasuda (2005) tvrdí, že predaj a distribúcia dlhopisov od menej známeho emitenta je nákladnejšia, ako pri emitentovi o ktorom má prostredie finančného trhu všeobecné povedomie. Pri neznámom emitentovi potrebuje investor dodatočné informácie, vzdelávanie sa, čo zvyšuje náklady na zamestnancov banky, ktorí musia byť preškolení tiež, aby dokázali potenciálneho investora presvedčiť o nákupe. Spomínané skutočnosti sú dôvodom, prečo aj informačné znalosti o emitentovi alebo dlhopisoch predstavujú relevantný faktor pri tvorbe ceny za upísanie dlhopisov. To akým spôsobom prebieha alokácia novej emisie medzi jednotlivých investorov je neoddeliteľnou súčasťou marketingových a cenových aktivít. Hlavným rozhodnutím o alokácii je určenie relatívnej váhy inštitucionálnych a retailových investorských fondov. Okrem tohto rozhodnutia je alokácia emisie ovplyvnená takými faktormi, ako je napríklad frekvencia účasti na nových emisiách upisovaných investičnou bankou, dlhodobý záväzok držať nové cenné papiere či recipročné obchody, ktoré môžu investori priniesť firme upisovateľa (Papaioanou a Karagozoglou, 2017).

1.3.2 Komerčné banky ako upisovateľ dlhopisov

V prípade záujmu o emisiu dlhopisov si emitenti až do roku 1989 mohli vybrať upisovateľa len spomedzi špecializovaných spoločností s cennými papiermi, ktoré boli prevádzkované ako samostatné divízie, resp. podniky určené a zriadené len za účelom upisovania cenných papierov. Po roku 1989 nastal vstup komerčných bánk do oblasti upisovania. Signifikantný rozmach pôsobnosti komerčných bánk nastal najmä po úplnom zrušení zákona *Glass Steagall Act* v roku 1999 a tak sa výber upisovateľov rozšíril o komerčné banky (Thau, 2010; Papaioanou a Karagozoglu, 2017).

Podľa autorov Papaioanou a Karagozoglu (2017) emitenti mali viac možností pri výbere upisovateľa práve po skončení 90. rokov. Po zrušení spomínaného zákona *Glass Steagall Act*, nastala situácia, keď veľké komerčné banky prevzali formou akvizície väčšinu spoločností poskytujúcich služby upisovania cenných papierov. V dôsledku veľkej konsolidácie celého odvetvia upisovania sa z komerčných bánk stávajú finančné domy, ktoré poskytujú rozsiahle a diferencované spektrum služieb. Výsledkom zániku špecializovaných inštitúcií na upisovanie cenných papierov, resp. ich prechod pod kontrolou komerčných bánk, stratila možnosť voľby medzi firmou s cennými papiermi a upisovacou firmou - pobočkov pridruženou k komerčnej banke veľkú časť svojho praktického významu.

Voľba emitenta sa sústreďuje okolo otázky: „Ktorý typ upisovateľa môže umiestniť nové cenné papiere s nižším podhodnotením¹ a nižšou kompenzáciou za upisovanie (hrubý *spread*)?“ Puri (1999) formuloval dve možné hypotézy súvisiace s komerčnou bankou, ktorá pôsobí ako upisovateľ.

Hypotéza „certifikácie“: Banka, ktorá má úverový vzťah s emitentom, má viac informácií o podnikaní svojho klienta vďaka dlhodobým vzťahom a neustálemu monitorovaniu bonity klienta. To dáva banke väčšiu informačnú výhodu oproti svojim konkurentom, iným investičným bankám ako certifikátora hodnoty novej emisie. Hypotéza „certifikácie“ teda predpovedá, že nové emisie sú menej podhodnotené, ak je upisovateľom ich komerčná banka. Táto informačná výhoda sa zvyšuje s neistotou a rizikovosťou okolo novej emisie, napr. IPO u dlhopisov nízkej kvality. Certifikácii, ako jednej z funkcií upisovateľa dlhopisov sa venujeme v podkapitole 1.5.

¹ Čím vyššie podhodnotenie dlhopisu tým vyššia výnosnosť dlhopisu a vyššie náklady emitenta na emisiu

Hypotéza „konfliktu záujmov“: Úverový vzťah môže vytvárať problém konfliktu záujmov, ak emitent zamýšľa použiť výnosy na splatenie alebo refinancovanie úverov, ktoré má v banke, zároveň slúžiacej ako upisovateľ. Banka môže mať záujem skresľovať finančné zdravie emitenta s cieľom dokončiť ponuku a získať späť svoje zdroje. V tomto prípade budú investori požadovať vyššiu cenovú zľavu, aby zmiernili svoj problém nepriaznivého výberu. Hypotéza „konfliktu záujmov“ preto predpovedá vyššie podhodnotenie nových emisií upísaných bankami, ktoré majú úverový vzťah s emitujúcou firmou.

Schenone (2004) analyzoval upisovanie emisie podnikového IPO banke alebo inej inštitúcii v období po roku 1989. V analyzovanej vzorke Schenone preukázal, že až 30 % firiem s predchádzajúcimi úverovými vzťahmi vstúpilo na trh so svojou komerčnou bankou, teda s bankou s ktorou už v minulosti malo nejaký finančný vzťah. Len 18 % podnikov z analyzovanej vzorky sa rozhodlo prejsť do inej investičnej banky. Zvyšok mal vzťah s bankou, ktorá nemohla vykonať IPO pre chýbajúcu pridruženú spoločnosť pre cenné papiere.

Yasuda (2005) konštatuje, že pri ponukách upisovania dlhopisov záleží nielen na predchádzajúcom, resp. existujúcom vzťahu banky s emitentom, ale podniky pri výbere upisovateľa berú ohľad aj na poplatky za upisovanie. Význam nižších poplatkov je menší pre cenné papiere (dlhopisy) s vyššou mierou informačnej asymetrie (*vid'. podkapitola 1.4.2*), ako sú napríklad dlhopisy zo špekulatívneho pásma. Yasuda (2005) konštatuje, že vzťahy emitenta s bankami majú pozitívny a významný vplyv na výber upisovateľa a to nad rámec ich vplyvu na poplatky. Tento výsledok je výrazne silnejší v prípade emitentov neinvestičných dlhopisov a prvoemitentov a takisto, že pôsobenie banky v úlohe sprostredkovateľa minulých úverov má najsilnejší vplyv na výber upisovateľa z pohľadu emitenta.

Bharath, Dahiya, Saunders a Srinivasan (2007) uvádzajú vyššiu pravdepodobnosť získania emisie dlhopisov alebo mandátu na upisovanie IPO komerčnou bankou, ak mal upisovateľ predchádzajúci úverový vzťah s emitentom. Ale úverové vzťahy nie sú signifikantnejšie pri ovplyvňovaní výberu upisovateľa v prípade druhotnej ponuky cenných papierov, pretože emitenti sú už overenými firmami na trhu s cennými papiermi a v dôsledku toho sú už známejšie. Narayanan, Rangan a Rangan (2007) tvrdia, že pravdepodobnosť výberu komerčnej banky za upisovateľa, s ktorou je emitent v úverovom vzťahu sa zvyšuje s rastúcou reputáciou a povesťou banky a to najmä na trhoch syndikátov a súkromného umiestňovania emisií a ak ide o počiatočnú verejnú ponuku dlhopisov a znižuje sa veľkosť

emisie. Investičné banky budú s väčšou pravdepodobnosťou emitentom vybrané, ak majú početnejšie zastúpenie na trhu upisovania dlhopisov v danom sektore, resp. krajine. (Narayanan, Rangan a Rangan, 2007)

1.3.3 Stanovenie ceny emitovaného aktíva

Podľa štúdie Jagannathan a Sherman (2006) sú informácie uverejňované emitentom v prospektoch a dokumentácii ohľadom emisie náležite vyhodnocované potenciálnymi investormi. Investori vykonávajú ohodnocovanie trhovej hodnoty podniku a to im umožňuje odhadnúť ponúkanú cenu dlhopisov. Okrem informácii uvedených v prospektoch sú mnohé emisie ovplyvnené špecifickými atribútmi, ktoré sú vyhodnocované v závislosti od emitenta a makroekonomických faktorov. To aj je dôvodom, prečo odhad ceny dlhopisu determinuje faktor úspechu IPO. Postupom času sa vyvinuli tri základné modely, ktoré sú využívané takmer na všetkých trhoch IPO pre stanovenie prvej ceny: *I. aukčný systém, II. Fixne stanovená cena, III. Metóda „book building“*. (Katti – Phani, 2016)

Základným rozdielom medzi aukčným systémom a fixne stanovenou cenou je v tomto prípade spoluúčasť investora pri tvorbe cien dlhopisov. Pri fixne stanovenej cene je tento proces stanovenia ceny zbavený vplyvu investorov a cena je určená na základe rozhodnutia emitenta. Z tohto dôvodu je presnosť stanovenej ceny pri emisii závislá na schopnosti emitenta zistiť odchýlku informačnej asymetrie medzi rôznymi typmi investorov a taktiež presnosť stanovenia ceny odráža sklon emitenta k riziku. (Katti – Phani, 2016)

Podľa zistení dvojice Katti – Phani (2016), IPO založené na aukčnom systéme vyústili do emisie s vyšším stupňom podhodnotenia, vyššou volatilitou, neúspechom pri atraktivite emisie vo vzťahu k dlhodobým investorom a riziku neupísania resp. upísania väčšieho objemu emisie ako je požadované, spomínané dôsledky sú výsledkom neefektívneho procesu stanovenia ceny emisie.

Model „book building“ je založený na spôsobe, ktorý umožňuje investorom podieľať sa na cene na základe dostupných informácií bez toho, aby medzi sebou vytvárali konkurenciu. Metóda „book building“ umožňuje emitentovi redukovať odchýlku významnosti informačnej asymetrie medzi rôznymi skupinami investorov a to tým spôsobom, že potencionálnym investorom umožňuje ohodnotiť dlhopisy v stanovenom rozsahu. Dôležitosť vzťahu medzi volatilitou trhu a metódou „book building“ je vyjadrený mierou podhodnotenia aktíva (Thau, 2010). Metóda „book building“, ktorá sa používa v Spojených štátoch a vo väčšine medzinárodných ponúk, dáva vedúcemu manažérovi úplnú

voľnosť pri prideľovaní nových cenných papierov medzi triedy investorov (Papaioanou a Karagozoglu, 2017).

Pre stanovenie ceny dlhopisu a jeho prvotné ocenenie je nutnosťou odhadnúť náklady na dlh emitenta. Damodaran (2011) opisuje proces stanovenia ceny, ako odhad nákladov na dlh pre firmu, kde rozlišuje tri zložky. Prvou je tzv. bezriziková miera výnosnosti (*angl. risk free rate*), ktorá tiež prispieva k nákladom na vlastný kapitál. Bezriziková sadzba sa vo všeobecnosti používa na odhad nákladov na vlastný kapitál a z toho dôvodu je potrebné použiť aj na výpočet nákladov na dlh. Ak sú náklady vlastného kapitálu založené na dlhodobej bezrizikovej sadzbe, ako to často býva, náklady na dlh by mali byť založené na rovnakej sadzbe. Bezriziková miera výnosnosti je však vnímaná ako teoretická miera výnosnosti, ktorú by investor očakával pri investícii s nulovým rizikom. Každá investícia s mierou rizika vyššou ako nula musí ponúkať vyššiu mieru výnosnosti. V praxi táto miera výnosnosti skutočne neexistuje: každá investícia nesie určité riziko, aj keď je toto riziko malé (Fabozzi a Fabozzi, 2021). Druhou zložkou je štandardný *spread* a v závislosti od analyzovanej firmy sa používajú dva prístupy. Ak má firma rating dlhopisov od etablovanej ratingovej agentúry, ako je S&P alebo Moody's, môžeme na základe ratingu odhadnúť predvolený *spread*. Ako ďalej Damodaran (2011) uvádza, v predkrízovom období bol štandardný *spread* pre dlhopisy s ratingom BBB vo výške dvoch percent a bol by použitý ako *spread* pre akúkoľvek spoločnosť s ratingom BBB. V roku 2010 boli zavedené *The Dodd-Frank Wall Street Reform a Consumer Protection Act* a v roku 2011 European Securities and Markets Authority (ESMA), tieto zákony mali zabezpečiť väčšiu trestnoprávnú zodpovednosť ratingových organizácií. Tieto regulácie by mali viesť k viac špecifickejšiemu odhadu rizika a *spreadu* pre emitentov. (Lee, 2010; ESMA, 2011) Tretia zložka je využívaná, ak firma nemá rating a má nesplatený dlh (napríklad bankové úvery), je možnosťou odhadnúť tzv. „syntetické“ hodnotenie firmy na základe jej finančných pomerov. Jednoduchý, aj keď efektívny prístup k odhadu syntetického pomeru je založiť ho výlučne na pomere úrokového krytia (EBIT/úrokové náklady) firmy. Daný postup je však v súčasnosti značne kritizovaný, nakoľko z výpočtu EBIT ukazovateľa sa vynecháva množstvo hodnotovo relevantných položiek, čím daný ukazovateľ menej odráža ekonomickú výkonnosť podniku. (Damodaran, 2011; Bouwens a kol., 2019)

1.4 Podhodnotenie emisie

Ako bolo spomenuté v predchádzajúcej podkapitole, jedna z hlavných funkcií upisovateľa je ohodnotenie emitenta a ocenenie emisie a teda dlhopisu. V minulosti sa niekoľko výskumov sústredilo na preskúmanie teórie, ktoré mali za úlohu vysvetliť úlohu finančného sprostredkovateľa v procese emisie IPO, nielen z pohľadu dlhopisov, ale aj z pohľadu akcií. Tieto štúdie prišli k relatívne podobnému záveru a to že práve kredibilita upisovateľa – sprostredkovateľa predstavuje dôležitý faktor (napr. Leland – Pyle, 1977; Campbell – Kracaw, 1980; Sherman, 1999).

Datta a kol. (1997) zistili, že IPO dlhopisov, ktoré patria do kategórie vysokého výnosu (špekulatívne) sú podhodnotené, zatiaľ čo IPO dlhopisov v kategórii investičného stupňa sú nadhodnotené. IPO dlhopisov investičného stupňa sú zvyčajne upísané prestížnymi upisovateľmi a naopak IPO špekulatívnych dlhopisov sú s väčšou pravdepodobnosťou spravované menej prestížnymi upisovateľmi. Štúdia ukázala, že kvalita investičných bánk je významným determinantom výnosov z IPO dlhopisov. Autori Chemmanur a Fulghieri (1994) tvrdia, že investori využívajú históriu predošlých emisií vykonaných upisovateľom, aby dokázali ohodnotiť jeho kredibilitu. Výsledky práce dvojice autorov Livingston – Miller (2000) taktiež naznačili, že väčší a prestížnejší upisovatelia (investičné banky) si účtujú signifikantne nižšie poplatky za upísanie emisie a to možno aj kvôli zohľadneniu aspektu výnosov z rozsahu, t.j., že väčšie investičné banky čerpajú z častejších zákaziek.

Práca dvojice autorov Loughan – Ritter (2002) sa sústredila na podhodnotenie emisie z pohľadu prerozdelenia zisku. V tomto prípade upisovateľ podhodnotí emisiu viac ako je potrebné, aby následne distribuoval zisk medzi najväčších klientov. V štúdiách (Jenkinson – Ljungqvist, 2001; Lowry a kol., 2004) sa objavuje tvrdenie o nedostatku verejne dostupných informácií o súkromnej spoločnosti, ktorá smeruje k IPO, čo je v súlade s tvrdeniami o informačnej asymetrii. Ďalšia skutočnosť pojednáva o tvrdení, že IPO predstavujú jedinečnú udalosť, ktorá nastáva iba raz počas životného cyklu spoločnosti, čo sťažuje empirické bádanie po príčinných súvislostiach s teóriami o uprednostňovaní upisovateľa. Fang (2005) ukázal, že ratingové agentúry dávajú vyššie ratingy tým emitentom dlhopisov, ktorí si najímajú upisovateľov s vyššou reputáciou a vyššia reputácia upisovateľov by tak mohla znížiť náklady emitentov na dlhopisy pozitívnym ovplyvnením ratingov. Investori a ratingové agentúry pri hodnotení rizika nesplatenia dlhopisov pravdepodobne zvažujú reputáciu finančných inštitúcií.

Liu a Ritter (2011) konštatujú, že trh IPO je možné charakterizovať ako trh, kde existujú lokálne oligopolné štruktúry, kde podhodnotenie emisie vo výške viac ako 20% pozorovali na IPO týkajúcich sa rizikových-neinvestičných dlhopisoch. Lou a Vasvari (2011) nadviazali na štúdiu Fanga (2005) a rozšírili poznatky v danej problematike o tvrdenie, že efekt audítorských spoločností s vyšším kapitálom reputácie na výnos dlhopisov je signifikantnejší ako vplyv renomovaných upisovateľov v oblasti ekonomického významu.

Zistenia Hearn (2014) naznačujú, že podhodnocovanie sa používa ako mechanizmus, ktorý má za úlohu stimulovať nadmerný dopyt (upisovanie) novo vydaných cenných papierov, aby sa vytvorila relatívne malá, ale veľmi rozptýlená a teda oslabená základňa menšinových vlastníkov emitovaných aktív. Dvojica autorov Katti a Phani (2016) dospela k záveru, že miera podhodnotenia dlhopisov pri IPO je dynamická a rôzne trhové sily interagujú súčasne pri pozorovaní zmien v oceňovaní nových emisií cenných papierov. Autori poukázali na význam regulačného rámca pri vysvetľovaní miery podhodnotenia IPO. Mahatidana a Yunita (2017) poukázali na existenciu štatisticky významného negatívneho vzťahu medzi reputáciou upisovateľa a podhodnotením emisie IPO na indonézscom primárnom trhu finančných a výrobných spoločností. Nagler a Ottonello (2021) použitím údajov o transakciách na úrovni upisovateľ-emitent, zistili, že upisovateľ, ktorý nepatrí medzi lídrov trhu s väčšou pravdepodobnosťou umiestni dlhopis a zvýši alokáciu na primárnom trhu emitentovi, s ktorým už má existujúci a periodicky sa opakujúci vzťah. Ten istý upisovateľ následne s väčšou pravdepodobnosťou odkúpi časť alokácie od toho istého emitenta do šiestich až dvanástich mesiacov po prvotnej ponuke.

Aj po udalostiach, ktoré nastali počas celosvetovej finančnej krízy v rokoch 2007 až 2009, je možné pozorovať, že americký trh podnikových dlhopisov sa stáva čoraz viac preupísaný (*angl. oversubscribed*) a aj napriek tomu ostáva cena dlhopisu v mnohých prípadoch podhodnotená. Preupísanosť dlhopisov môžeme zjednodušene vysvetliť ako jav, pri ktorom na trhu dopyt prevyšuje ponuku. Je pravdou, že podhodnotenie v priemere na jeden dlhopis je nízke, avšak za predpokladu, že emisie sú časté a ich objemy vysoké, v takom prípade je zisk v prvom dni pre investorov na primárnom dlhopisovom trhu signifikantný (Nikolova a kol., 2020). Harvey a kol. (2018) definuje pojem preupísanosť ako jav, ktorý nastáva, ak investori nie sú schopní kúpiť všetky akcie alebo dlhopisy, ktoré požadujú. V takom prípade sú upisovatelia nútení rozdeliť akcie alebo dlhopisy medzi

investorov. K tomu vo väčšine prípadov dochádza, keď je nová emisia podhodnotená alebo je po nej veľký dopyt z dôvodu perspektívy rastu. (Harvey a kol., 2018)

Autori Heeley a kol. (2007) pri výskume podhodnocovania IPO konšatovali, že technologické spoločnosti vytvárajú ideálne prostredie pre vznik jednak podhodnotenej emisie a informačnej asymetrie. Daná skutočnosť je výsledkom povahy technologických spoločností. Hlavnú rolu vo väčšine technologických spoločností zohráva inovačný proces. Práve existencia inovačného procesu, na ktorom sú technologické spoločnosti postavené, predstavuje pre externých investorov pomerne neprehľadný a ťažko čitateľný jav. Jain a kol. (2008) potvrdzuje uvedenú skutočnosť tvrdením, že väčšina technologických spoločností emituje cenný papier na základe vízie ziskov v budúcnosti, no nie v prítomnosti.

Na základe vyššie uvedených tvrdení je možné konštatovať, že IPO sú v priemere podhodnotené. Tvrdenia viacerých autorov z uvedených štúdií argumentujú (Baron, 1982; Hanley, 1993; Loughran-Ritter, 2002), že podhodnocovanie emisie je spôsobom nepriamej kompenzácie nákladov upisovateľovi. Podhodnotením emisie nastáva situácia, keď emitent prichádza o možné zdroje, nakoľko hrubý *spread* emisie je typicky zmluvne dohodnutý ešte pre finálnym stanovením ceny aktíva emisie. Ako uvádza Bessembinder a kol. (2020) nadmerná alokácia dlhopisov medzi investorov je pre syndikát pri prvotných ponukách dlhopisov potenciálne nákladnejšia.

1.4.1 *Spread upisovateľa – hrubý spread*

Hrubý *spread* sa vzťahuje na poplatky, ktoré upisovatelia dostávajú za sprostredkovanie a upisovanie ponuky dlhových alebo majetkových cenných papierov. Čím vyššia je cena emitovaného aktíva, tým vyššiu odmenu, resp. tržbu z emisie si upisovateľ dokáže uplatniť voči emitentovi. Ako spomínajú autori Papaioanou a Karagozoglu (2017) upisovací *spread* (hrubý *spread*), možno nazvať zjednodušene aj ako kompenzáciu za služby poskytnuté emitentovi. V rámci najkomplexnejšej upisovacej zmluvy, teda zmluvy o záväzku, tieto služby zahŕňajú vznik, upisovanie (poistenie), marketing a cenotvorbu a umiestnenie emisie. Náklady na poskytovanie týchto služieb zahŕňajú fixnú aj variabilnú zložku nákladov.


Fixné náklady zahŕňajú služby, ktoré sú spoločné pre všetky typy emisií a vznikajú bez ohľadu na veľkosť respektíve výnosnosť samotnej emisie. Fixné náklady zahŕňajú náklady, ktoré upisovatelia vynaložia na ich zapojenie do prípravy a podania emisie u regulátora príslušného trhu, organizovanie roadshow a predstavenie emisie potenciálnym

investorom, vykonávanie due diligence, ako aj zisťovanie a ohodnocovanie emisie (Thau, 2010; Papaioanou a Karagozoglou, 2017).

Variabilné náklady zahŕňajú výdavky nad rámec fixných nákladov a líšia sa podľa náročnosti odhadu hodnoty emisie, rozsahu marketingového úsilia, intenzity a rozsahu aktivít umiestňovania. Od určitej úrovne objemu emisie sa zvyšujú náklady na vydanie, keďže úsilie umiestniť väčšie emisie sa stáva nákladnejším. Ak F sú celkové fixné náklady na celkové úsilie, ktoré musí upisovateľ vynaložiť, v sú variabilné náklady na jednu peňažnú jednotku výnosov a K predstavujú objem emisie, v takom prípade hrubý *spread* S , je vyjadrený ako percento objemov nasledovne: (Papaioanou a Karagozoglou, 2017)

$$S = \frac{F}{K} + v$$

Vyššie uvedený výraz znamená, že v prípade ak objem emisie K rastie, priemerné fixné náklady F/K klesajú. Ak variabilné náklady v sú konštantné bez ohľadu na veľkosť výnosov, potom hrubý *spread* S bude klesať, keď objem emisie bude stúpať. Proces upisovania teda využíva úspory z rozsahu, ktoré prinášajú často pozorovaný inverzný vzťah medzi hrubými *spreadmi* (S) a objemom . Variabilné náklady však nemusia byť neustále konštantné, pretože objemy sa zvyšujú. V prípade, ak objem emisie rastie, upisovateľ musí vynaložiť väčšie úsilie a zdroje na uvedenie emisie na trh a certifikáciu jej hodnoty. V takom prípade variabilné náklady v môžu začať rásť, keď objem emisie prekročí určitú úroveň. To znamená, že nad určitou úrovňou objemu musí upisovateľ čeliť možnosti, že nebude dosahovať úspory z rozsahu, nakoľko variabilné náklady na jednu peňažnú jednotku rastú rýchlejšie ako fixné náklady na jednu peňažnú jednotku objemu (priemerné fixné náklady) . Percentuálne vyjadrený hrubý *spread* sa začne zvyšovať spolu s výnosmi. Jav, že nevznikajú úspory z rozsahu naznačuje, že hrubý *spread* nasleduje krivku v tvare písmena U vo vzťahu k výnosom, ako je znázornené na obrázku 2 (Altinkılıç a Hansen, 2000). Nižšie uvedený obrázok 2 opisuje vzťah medzi hrubým *spreadom* a objemom emisie. Krivky S_{lo} a S_{hi} znázorňujú vzťah hrubého *spreadu* k výnosom z emisie pre emitentov nižšej (vyššej) kvality vyžadujúcich viac (menej) služieb spojených s emisiou dlhopisov. Krivka S znázorňuje vzťah hrubého *spreadu* a objemov emisie odvodených od rôznych kombinácií skupín menších (nižšia kvalita) a väčších (vyššia kvalita) emitentov. Body ležiace na myslenej priamke ab ilustrujú úrovne výnosov z emisie, nad ktorými sa už neprejavuje existencia úspor z rozsahu, čo má za následok zvýšenie hrubých *spreadov* s veľkosťou emisie pre každú kategóriu emisií.



Obrázok 2 Vzťah medzi hrubým spreadom a objemom emisie

Zdroj: (Altinkılıç a Hansen, 2000).

Altinkılıç a Hansen (2000) prezentujú vyššie opísanú štruktúru hrubého spreadu a tvrdia, že banky rôznej kvality vytvárajú spektrum vzťahov alebo kriviek medzi spreadom a objemom. Menej kvalitné (zvyčajne menšie) banky realizujú úspory z rozsahu (t. j. rýchlo rastúce variabilné náklady) pri nižšom rozsahu objemu. Ak by sa takéto banky rozhodli zvýšiť objemy, krivka *spreadu* by prudko stúpala od spodného bodu. Je to tak preto, že získanie väčšieho množstva prostriedkov si vyžaduje úmerne väčšie úsilie a zdroje na jednu peňažnú jednotku kapitálu, aby sa zabezpečilo úspešné dokončenie obchodu. Na druhej strane vysokokvalitné (zvyčajne veľké) firmy čelia úsporám z rozsahu pri oveľa vyšších úrovniach objemu. Preto každý typ firmy čelí inej krivke objemov. Keď sa *spready* spriemerujú pre všetky typy emisií, získame hodnotu, ktorá je opísaná klesajúcou krivkou *spreadu*, ktorá implikuje úspory z rozsahu. Altinkılıç a Hansen (2000) zistili, že variabilné náklady rastú rýchlejšie nad úroveň objemov a v dôsledku toho tvrdia, že hrubé *spready* vykazujú krivku v tvare U vo vzťahu k výnosom. Okrem toho hraničné náklady rastú rýchlejšie pri menšom objeme emisie, resp. emisie nižšej kvality.

Okrem hrubého *spreadu* sa v literatúre stretávame s implicitným *spreadom*. Implicitný *spread*, resp. rozpätie je rozdiel medzi prvou trhovou cenou nového cenného papiera na sekundárnom trhu a prvotnou cenou IPO. Ak je tento rozdiel kladný, t. j. trhovú cenu prevyšuje cenu IPO, predstavuje to podhodnotenie emisie. Kladný implicitný *spread* zachytáva to, čo sa často nazýva „peniaze ponechané na stole“, pretože emitent predáva novú emisiu za cenu nižšiu, ako je jej počiatočná trhovú cenu. Ide o nepriame náklady emitenta, ktoré vznikli vo forme vyššej než investormi očakávanej výnosnosti dlhopisu. Naopak, ak sa ukáže, že trhovú cenu je nižšia ako prvotná cena stanovená pri IPO, nová emisia sa považuje za nadhodnotenú (*angl. overpricing*). Negatívny implicitný *spread* predstavuje pre emitenta lacnejšie získaný kapitál než by bola trhom určená cena (výnosnosť) a teda pomáha znižovať variabilné náklady (Thau, 2010; Papaioanou a Karagozoglu, 2017).

Otázkou je, prečo upisovatelia v priemere emisiu podhodnocujú. Investičné banky – upisovatelia profitujú z podhodnotenia emisie v dvoch aspektoch. Prvým dôvodom je, že nižšie stanovená cena emisie im dokáže zjednodušiť nájsť potenciálnych záujemcov resp. kupcov pre predmetnú IPO, čo sa odzrkadľuje aj napr. v znížení marketingových nákladov v súvislosti s danou emisiou. Druhým dôvodom podhodnocovania emisie je podpora správania investorov v dobývaní renty (*angl. rent-seeking behaviour*). Dobývanie renty značí v ekonomickej teórii cieľavedomú činnosť, pri ktorej skupina, alebo jednotlivci využívajú svoje disponibilné zdroje k zaisteniu monopolných práv a postavenia. Výsadné práva a postavenie získava upisovateľ pri rozhodovaní o tom ako bude alokácia rozdeľovaná medzi investorov a ako bude podhodnotená. Vysoké podhodnotenie často značí veľký dopyt zo strany investorov a upisovateľ tak uprednostnením investora môže získať výhody, pričom náklady spojené s podhodnotením preberá emitent. Daná činnosť sa označuje ako škodlivá pre voľný trh, nakoľko vedie k stratám u ekonomických subjektov, ktorí danou výhodou neoplvávajú (Krueger, 1974; Tullock, 2003; Clark, 2016).

Vyššie spomenuté výsledky uskutočnených štúdií sumarizujú aj autori Papaioanou a Karagozoglu (2017), ktorí tvrdia, že kauzálne pozorovania a rozsiahly empirický výskum v Spojených štátoch a iných krajinách priniesli silné dôkazy, že signifikantné množstvo nových emisií je podhodnotených. Autori sa vyjadrili, že problematika podhodnotenia sa týka priemerných hodnôt výnosov, ako aj mediánu hodnoty počiatočných výnosov nameraných od prvotnej ponuky ceny po uzatváraciu cenu prvého obchodného dňa, ktorých výsledky sú kladné a štatisticky významné.

Väčšina vyššie spomenutých teórií podhodnotenia emisie predpokladá, že emitenti, upisovatelia a investori majú k dispozícii rôzne súbory informácií alebo presvedčení o hodnote novej emisie. Tieto heterogénne presvedčenia vytvárajú rozdielne cenové predpoklady, v ktorých je prvotná cena stanovená pod očakávanou trhovou hodnotou. Predpoklad heterogénnej informácie vytvoril dve rôzne línie teórií:

- I) teóriu signalizácie (*angl. signaling theory*);
- II) teóriu asymetrickej informácie (*angl. information assymetry theory*).

Rozdiel medzi týmito dvoma teóriami je v povahe motívu podhodnotenia. V signalizačných teóriách je podhodnotenie zámerným rozhodnutím ukázať skutočnú hodnotu firmy, aby investori pri následných oceneniach prehodnotili cenný papier, aby prispôsobili jeho cenu jeho skutočnej trhovej hodnote (Rock, 1986; Welch, 1989). Podhodnotenie cenného papiera ako také je ďalším signalizačným mechanizmom podobným tradičnejším metódam, ako je dividendová politika a kapitálová štruktúra (Fisch, 2019).

V asymetrických informačných teóriách je podhodnotenie emisie optimálnym riešením pri riešení informačných výhod, ktoré môžu mať príslušné strany voči sebe navzájom. Signalizačné teórie podhodnotenia predpokladajú, že manažéri emitujúcich firiem vedia viac o kvalite svojich firiem ako externí investori. Pri nedokonalých informáciách investori nedokážu rozlíšiť medzi kvalitnými firmami a firmami nižšej kvality. Preto sa vysokokvalitné firmy rozhodnú podhodnotiť svoju novú emisiu, aby signalizovali ich skutočnú hodnotu. Dôležitým javom týchto modelov je, že skutočná kvalita firmy je odhalená skôr, ako firma podnikne kroky, ktoré spustia nové ocenenie po uskutočnení emisie.

1.4.2 Informačná asymetria

Bez ohľadu na nesporné výhody prvej verejnej ponuky cenných papierov, na základe už uskutočnených štúdií je potvrdená existencia informačnej asymetrie medzi shareholdermi firiem (napr. vlastníci a manažéri) a externými investormi spolu. V teórii kontraktov a ekonomickej teórii sa informačná asymetria zaoberá štúdiom rozhodnutí v transakciách, kde jedna strana má viac alebo lepšie informácie ako tá druhá. Existencia informačnej asymetrie vytvára nerovnováhu síl v obchodných transakciách, čo môže niekedy spôsobiť, že transakcie budú neefektívne, alebo v najhoršom prípade spôsobí zlyhanie trhu (Akerlof, 1970; Zavolokina a kol., 2021). Za cieľom zníženia, resp. obmedzenia miery informačnej

asymetrie, je potrebné, aby boli obom stranám poskytnuté relevantné informácie (Zavolokina a kol., 2021). Mechanizmy reputácie poskytujú jeden zo spôsobov, ako zlepšiť dôveru a takéto mechanizmy sa v minulosti úspešne aplikovali (Fuller a kol., 2007). Na zvýšenie dôvery v oblasti IPO by sa preto mala zabezpečiť transparentnosť všetkých zúčastnených subjektov. (Söllner a Leimeister, 2013). V spojitosti s existenciou neistoty ex-ante, týkajúcou sa napríklad hodnoty firmy, môže takáto situácia viesť podľa uskutočnených štúdií k podhodnoteniu IPO (Beatty – Ritter, 1986; Carter – Manaster, 1990). V nadväznosti na uvedené tvrdenie uskutočnili autori Premti a Madura (2013) výskum, kde analyzovali informačnú asymetriu vybraných IPO počas období hospodárskeho rastu aj poklesu. V období hospodárskeho poklesu, je ako dôsledok informačnej asymetrie medzi firmami a externými investormi pozorované, že takéto firmy môžu pred IPO získať vyššie ocenenie, ako si zaslúžia v čase ich IPO, čo vysvetľuje ich následnú dlhodobú nedostatočnú výkonnosť. Zistenia Yahya a kol. (2019), o vzťahu medzi informačnou asymetriou a veľkosťou podniku ukazujú, že veľkosť firmy, vyjadrená prostredníctvom trhovej kapitalizácie, je pozitívne signifikantná na vysvetlenie tzv. zaisteného pomeru aktíva (*angl. lock-up ratio*). Čím väčší pomer sa podarí umiestniť medzi majoritných akcionárov, tým dokáže upisovateľ signalizovať, že podnik je v dobrej kondícii, resp., že emisia má dobré výkonnostné parametre (likvidita a výnosnosť). Výsledky naznačujú, že firmy, ktoré majú vyšší pomer lock-up ratia záväzku u majoritných akcionárov ako voči externým investorom môže podľa Yahya a kol. (2019) slúžiť ako mechanizmus na signalizáciu kvality IPO.

Peng a Brucato (2004) uskutočnili štúdiu, ktorá sa zaoberala problematikou výskytu informačnej asymetrie pri IPO dlhopisov na úrovni miest a samospráv. V záveroch výskumu autori konštatujú, že v prípade existencie informačnej asymetrie by emitenti mali zvážiť najatie prestížnejších upisovateľov, aby takýmto spôsobom znížili náklady na emisiu a odporúčajú emitentom s dobrým podkladovým úverovým ratingom (rizikový stupeň 7 a nižší) uverejnenie podkladov pre emisiu k dispozícii potencionálnym investorom. Ďalšími dôležitými faktormi pre úspešnosť emisie je podľa Krebbers a kol. 2023 tvrdenie, že dopyt po podnikových dlhopisoch úzko súvisí s faktormi spojenými s kreditným rizikom a prítomnosťou emitujúcej firmy na dlhopisovom trhu. Výsledky ukázali, že dopyt po dlhopisoch je nižší v prípade firiem s vysokou mierou zadlženosti, debutujúcich emitentov ale aj u emitentov, ktorí sa na trhu vyskytujú pomerne často. Uvedený výskum nadviazal na autora Siani (2019), ktorý tvrdí, že firmy sú ovplyvnené dopytovými šokmi rozdielne a to v dôsledku ich vzťahov s upisovateľom. Firmy, ktoré sa na trhoch vyskytujú častejšie, majú

väčší dopyt po emitovaných dlhopisoch a dosahujú nižšie podhodnotenie. Okrem toho vydávajú viac (väčšie objemy) dlhopisov. Siani (2019) to interpretuje ako dôkaz, že vzťahy medzi bankami a investormi sú primerane stále a trvácne. Uvedený mechanizmus spočíva v tom, že upisovatelia čelia nákladnému vyhľadávaniu investorov pri alokácii nových dlhopisov emitenta.

1.5 Certifikácia dlhopisov

Certifikácia dlhopisu predstavuje ďalšiu z funkcií upisovateľa, keď upisovateľ potrebuje presvedčiť investorov, že cena IPO je správne ohodnotená. Danú funkciu upisovateľov dlhopisov skúmali autori Anders, Betzer a Limbach (2014), kde okrem teoretických poznatkov, opísaných ako certifikačná hypotéza, predložili závery, že dlhopisy s vysokým výnosom, ktoré boli upísané renomovanými investičnými bankami sú spojené s výrazne vyšším implicitným rizikom. Spomínaná štúdia nadviazala na autorov Booth a Smith (1986), ktorí tvrdia, že investičné banky ako opakovaní účastníci trhu IPO ponúkajú certifikáciu pre emitujúce firmy. Vkladom svojej povesti môžu zabezpečiť kvalitu IPO firmy potenciálnym investorom.

Autori Anders, Betzer a Limbach (2014) argumentujú výsledkami štúdie, kde sa ukázalo, že dlhopisy, ktoré boli upísané jedným z troch najväčších upisovateľov IPO na americkom trhu korporátnych dlhopisov, majú znateľne vyššiu pravdepodobnosť poklesu ich hodnoty v krátkodobom aj strednodobom časovom horizonte, alebo nenaplneniu záväzkov zo strany emitenta. Pri certifikácii emisie dlhopisov je potrebné spomenúť aj výsledky práce Dunbara (2000), ktorý tvrdí, že pokiaľ ide o IPO v USA, investičné banky so slabým výkonom z hľadiska certifikácie IPO, cien a pokrytia výskumu následne strácajú trhovú podiel. Okrem USA, bol fenomén certifikácie skúmaný aj na Čínskom IPO trhu (Ding a kol., 2007; Kao a kol., 2009; Huyghebaert a kol., 2015), kde autori prišli k zhodným názorom, že firmy si vyberali pre svoje uvedenie na trh vedúcich upisovateľov s nižšími štandardami hodnotenia, čo malo za následok nepresné nadhodnotenie daného IPO a jeho zvýšenú cenu.

Implicitné riziko pri dlhopisoch je kritickým problémom, ktorý na seba upriamuje pozornosť všetkých záujmových skupín na trhu s dlhopismi a to z dôvodu, že súvisí s výkladom regulácie predmetného trhu, nákladmi na podnikové financovanie a rozhodnutiami jednotlivých investorov. Dôležitú úlohu pri vyhodnocovaní implicitného

rizika zohrávajú ratingové agentúry, nakoľko ich hodnotenia chránia investorov, redukujú informačnú asymetriu a pomáhajú rozvíjať trh s dlhopismi (Chen – Zhao, 2019).

1.5.1 Rating dlhopisov a ratingové agentúry

Ratingové agentúry, ktorých primárnou úlohou je sprostredkovanie informácií, dokážu mať významný vplyv na kapitálovú štruktúru firiem, kapitál, investície a rast hodnoty firmy (Tang, 2009). Význam ratingových agentúr v rámci zabezpečenia fungujúceho finančného a kapitálového trhu bol zvýšený kontrolou a dohľadom nad ratingovými agentúrami (Sangiorgia – Spatt, 2017), už spomínanými zákonmi a reguláciami v roku 2010 *The Dodd-Frank Wall Street Reform and Consumer Protection Act* a v roku 2011 ESMA, aby bola dosiahnutá trestnoprávna zodpovednosť ratingových organizácií.

Rating, ktorý ratingová agentúra udelí predstavuje hodnotenie úverovej bonity emitenta a jeho schopnosti a ochote splácať svoj dlh v plnom rozsahu a stanovenom čase (Bissoondoyal-Bheenick, 2005). Rating nie je vo vyspelých trhových ekonomikách obligatórny, bez neho by však umiestnenie emisie na trh bolo výrazne drahšie, v niektorých prípadoch dokonca neuskutočniteľné. Vytvorenie ratingového ohodnotenia je prospešné, pretože syntézou vytvára komplexné ohodnotenie rozličných prvkov systému riadenia emitenta (Turrent – Ariza, 2016). Vo všeobecnosti predstavuje kreditný rating významnú súčasť procesu pri ohodnocovaní rizika, ktoré so sebou nesie cenný papier alebo kreditné riziko emitenta. Zlyhanie ratingov pri zaistených dlhových obligáciách (CDO, *angl. Collateralized debt obligation*) počas celosvetovej hospodárskej krízy v rokoch 2007-2008, podobne ako významné podhodnocovanie podnikových rizík v súvislosti s nástupom nedávnych finančných kríz (Európska dlhová kríza), podnecujú vedcov k úvahám a prehodnocovaniu techník, ktorými sú ratingy stanovené. Ako argumentuje Pertaia a kol. (2021) konštrukcia a výpočet ratingu sú realizované na základe zastaraných a jednoduchých metód vychádzajúcich z investičného portfólia. Táto metóda obsahuje neadekvátne metriky, ako napríklad stimulovanie nadmerného vystavenia sa riziku a podporovanie nesprávneho oceňovania úverového rizika, ktoré by mali byť predmetom zmeny. Analytici ratingových agentúr často vyžadujú od spoločnosti finančné informácie, aby mohli priradiť a vydať ratingový stupeň. Takýmto spôsobom stanovený rating zahŕňa niekoľkoročné auditované ročné účtovné závierky, prevádzkové a finančné plány, postupy riadenia a iné úverové premenné ovplyvňujúce rizikový profil subjektu. Niektoré agentúry tvrdia, že do rizikového profilu integrujú rozsah pravdepodobných strát a miery návratnosti. Metóda, ktorá má za

úlohu spomínaný proces mapovať, však nie je sprístupnená a táto informácia má len malý vplyv na ratingy ako súčasť rizikového profilu emitenta alebo cenného papiera. Ako sa uvádza v štúdiách Bolton a kol. (2012) Mathis a kol. (2009), ratingové agentúry sú finančne postihované za ich neschopnosť a oneskorenie pri identifikácii potenciálnych rizík emitentov dlhopisov a projekcii ich možnej budúcej insolventnosti. Ako uvádza Hu a kol. (2020) v celosvetovom ponímaní úverových ratingov sú najrešpektovanejšie globálne ratingové organizácie – tzv. veľká trojka. Podľa Hu a kol. (2020) a Smale (2016) až 95 percent všetkých úverových ratingov prideluje „veľká trojka“ čo predstavuje spoločný názov pre najväčšie ratingové agentúry – Standard and Poor's, Moody's a Fitch. Použitím svojich sofistikovaných hodnotiacich kritérií sú schopné ovplyvniť trhové ceny dlhových emisií signalizáciou kreditnej kvality emitentov dlhopisov alebo odhalením skutočného kreditného stavu emitentov dlhopisov. Najvýznamnejšie podnikové dlhopisy na americkom trhu sa na trh uvádzajú práve s ratingom od spoločností Moody's a Standard and Poor's, pričom nižší rating sa používa na kategorizáciu dlhopisov (Bongaerts a kol. 2012).

Od roku 2005, keď index Lehman Brothers (americká investičná banka) zahrnul Fitch ako tretiu ratingovú agentúru na skúmanie ratingových kategórií dlhopisov, sa začal využívať na stanovenie ratingu dlhopisu tzv. stredný rating, ktorým daný cenný papier alebo spoločnosť tri ratingové agentúry ohodnotili súčasne (Chen a Wang, 2021). Aj napriek tomu, že daný systém ohodnocovania nie je dokonalým, či dokonca niektorými autormi považovaný za zastaraný a neaktuálny (Mathis a kol., 2009; Bolton a kol., 2012; Pertaia a kol., 2021) sa aj veľké centrálné banky spoliehajú na ratingové agentúry pri hodnotení akceptovateľných aktív, ktoré sa majú kúpiť v rámci ich programov nákupu aktív – bežne označovaných ako kvantitatívne uvoľňovanie (Abidi a kol., 2019). Kraft (2015) vo svojej práci zdôrazňuje, že ratingové agentúry vo svojich hodnoteniach zvažujú nielen finančné vlastnosti emitenta, ale aj tzv. mäkké informácie (*angl. soft information*), ako je napríklad kvalita manažmentu, riadenie a zaobchádzanie s rizikom, sektor, resp. odvetvie, v ktorom daný podnik pôsobí či vzťahy manažmentu spoločnosti s veriteľmi. Úverové ratingy možno rozdeliť do dvoch úrovní, ktoré sa bežne nazývajú hodnotenie. Hodnotenie môže mať dve kategórie: i) investičný stupeň a ii) špekulatívny stupeň (neinvestičný). Investičný stupeň obsahuje len dlhopisy s ratingom priradeným v intervale AAA až BBB- (Thau, 2010). Všetky ratingy obsahujú aj okolnosť, keďže AAA (Aaa) znamená „Najvyššia kvalita emitenta“, interval AA+ až AA- znamená „Silná platobná kapacita emitenta“ a ratingy

v intervale B+ a nižšie sú opísané „Vysoké úverové riziko“, resp. možného zlyhania emitenta.

1.6 Reputácia upisovateľa

Jedným z dôležitých aspektov pre úspešné umiestnenie a realizáciu emisie je nájdenie vhodného upisovateľa dlhopisov. Jedným z relevantných parametrov, ktorý bol spomínaný v predchádzajúcej podkapitole 1.4 je reputácia upisovateľa. Reputáciu upisovateľa možno vyjadriť na základe charakteristík ako je: (Papaioanou a Karagozoglu, 2017): I. podiel na trhu, II. frekvencia a umiestnenie v prospektoch, III. Carter-Manaster ranking, IV. modifikovaný Carter-Manaster ranking, V. centralizovanosť vedúceho upisovateľa. V literatúre sa najčastejšie udáva podiel na trhu ako podiel celkových hrubých výnosov investičnej banky z emisií IPO za určité časové obdobie, ktorým je spravidla jeden kalendárny rok. Čím vyšší výnos investičná banka získa z emisií IPO, tým je vnímaná ako prestížnejšia. Ďalším z parametrov na vyhodnotenie reputácie upisovateľa je frekvencia a umiestnenie v prospektoch. Daný parameter udáva pomer, ako často sa investičná banka uvádza v jednotlivých prospektoch emisie a zároveň berie ohľad aj na umiestnenie a teda, či ide o vedúceho upisovateľa, resp. o poradie v syndikáte upisovateľov.

Klasifikačná metóda nazývaná podľa jej autorov Carter-Manaster ranking je variáciou metódy frekvencie a umiestnenia v prospektoch emisií. Každému upisovateľovi – investičnej banke, táto metóda pridelí explicitnú váhu v závislosti od frekvencie, s akou sa upisovateľ objavuje v prospektoch a v závislosti od jej poradia pre danú emisiu. Upisovatelia sú potom zoradení podľa ich zloženého skóre (Carter a Manaster, 1990). Modifikovaný Carter-Manaster ranking priradzuje upisovateľom, ktorí sú vo vedúcej skupine a teda sú hlavnými upisovateľmi hodnotu 3, upisovateľom, ktorí sa umiestňujú medzi hlavnými upisovateľmi, no nie sú vedúcimi emisie hodnotu 2, upisovateľom, ktorí sa emisie zúčastňujú ako súčasť syndikátu hodnotu 1 a všetkým ostatným upisovateľom hodnotu 0 (Johnson a Miller, 1988). Carter a Dark (1992) preukázali, že Carter-Manaster ranking má ako štandard prestíže väčšiu vysvetľujúcu silu ako modifikovaná stupnica Carter-Manaster od Johnsona a Millera. Bajo a kol. (2016) vyvinuli komplexnejší ukazovateľ sily reputácie upisovateľa, ktorý meria, centralizáciu upisovateľa v sieti investičných bánk a investorov. Čím je upisovateľ centrálnejšie umiestnený, tým disponuje rozsiahlejšou a trvalejšou sieťou vzťahov, ktoré má upisovateľ s inými upisovateľmi a prostredníctvom nich aj s inými investormi. Centrálne umiestnení upisovatelia môžu prilákať viac inštitucionálnych

investorov a sú schopní získať viac informácií súvisiacich s emisiou, čo môže mať za následok zlepšenie výkonnosti novej emisie. V literatúre existuje množstvo empirických dôkazov, že výber upisovateľa dlhopisov ovplyvní úspešnosť emisie dlhopisov na primárnom trhu (Fang, 2005; Yasuda, 2005; Andres a kol., 2014; Carbo-Valverde a kol., 2017), ako aj výsledky štúdií zameraných na sekundárny trh (Dick-Nielsen a kol., 2012). Zistenia, ktoré prezentovali Dick-Nielsen a kol. (2021) naznačujú, že vyššie spomínané výhody úspešnosti emisie vo vzťahu k výberu upisovateľa, aspoň čiastočne, vznikajú vďaka silnému vzťahu medzi upisovateľom a emitentom. Vzťah bolo možné pozorovať, medzi kreditným rizikom hlavného upisovateľa a kreditným rizikom emitujúcej firmy, ktorý vykázal pozitívnu závislosť. V prípade, ak emitenti odvodzujú hodnotu kapitálu zo vzťahu s upisovateľom naznačuje to, že emitenti môžu profitovať z certifikácie predmetného emitovaného cenného papiera, pokiaľ má ich upisovateľ vysoké kreditné hodnotenie (Burch a kol., 2005). V súlade s týmto argumentom je aj tvrdenie autorov Dick-Nielsen a kol. (2021), že proces certifikácie hlavným upisovateľom pomáha pri znižovaní asymetrických informácií medzi emitentom a investormi, čo v konečnom dôsledku vedie k vyššej cene na primárnom trhu (Fang, 2005; Carbo-Valverde a kol., 2017).

Dick-Nielsen a kol. (2021) merali pri podnikových dlhopisoch tesnosť vo vzťahu medzi emitentom a upisovateľom tak, že najprv identifikovali hlavných upisovateľov všetkých v súčasnosti nesplatených dlhopisov. *Spread* swapu na kreditné zlyhanie (CDS, *angl. credit default swap*) každého hlavného upisovateľa, ako formu náhrady za prenesené kreditné riziko, sa následne vážilo v pomere k počtu aktuálne nesplatených dlhopisov firiem, ktoré upisovateľ upísal. V takomto prípade bude miera tesnosti vo vzťahu k skúmanej firme vysoká, ak sa dominantný hlavný upisovateľ dostane do finančnej tiesne, resp. bude pre neho problematické získať investorov pre emisiu. Pomocou uvedeného postupu merania autori ukázali, že úverové riziko upisovateľa pomáha vysvetliť *spready* CDS emitentov dlhopisov. V súlade s certifikačnou hypotézou Dick-Nielsen a kol. (2021) zistili, že citlivosť úverového rizika firiem na finančné ťažkosti upisovateľa je väčšia u emitentov špekulatívneho stupňa, t. j. presne u tých, ktorí by z certifikácie profitovali najviac. Ako autori uvádzajú, v skúmanom časovom období od roku 2004 do roku 2012 existuje niekoľko veľkých upisovateľov, ktorí zlyhali, najmä *Bear Stearns*, *Lehman Brothers* a *Wachovia*.

V prípade ak je vzťah upisovateľa a emitenta hodnotný, by podľa očakávaní v takom prípade finančný problém upisovateľa mal väčší vplyv na firmy s bezprostrednou potrebou upísania emisie dlhových cenných papierov. To by bol napríklad prípad firiem s vysokým

podielom krátkodobého dlhu. Nakoľko firmy zvyčajne prevedú splatný dlh, tieto firmy budú nútené čoskoro opätovne emitovať dlhopisy (Opler a kol., 1997; Hovakimian a kol., 2001). Uvedené konštatovanie podporili aj výsledky Dick-Nielsen a kol. (2021), ktorí naznačili, že finančné problémy upisovateľov sú rizikovejšie pre podniky s veľkým objemom dlhu splatnom v priebehu budúceho roka, t. j. firmy s vysokou expozíciou voči *rolloveru*.

Carbo-Valverde a kol. (2017) skúmali proces párovania medzi emitentom a upisovateľom pri emisii podnikových dlhopisov bankami aj priemyselnými spoločnosťami. Autori skúmali kombinovaný súbor údajov podnikových dlhopisov emitovaných v Európe v rokoch 2003–2013 bankami a nefinančnými spoločnosťami. Zistili, že banky mali v sledovanom období nižšiu pravdepodobnosť zhody s renomovaným upisovateľom v porovnaní s nefinančnými spoločnosťami. Nižšia pravdepodobnosť pre banky, resp. bankové inštitúcie vznikla počas celosvetovej hypotekárnej krízy (2007-2008) a európskej dlhovej krízy (2011-2012), v ktorých boli šance na upísanie emisie renomovaným upisovateľom približne od 5,02-krát do 10,92-krát nižšie pre bankové inštitúcie, ako pre emitentov v iných odvetviach. Pred krízou sa však nezistili žiadne rozdiely. Výsledky tiež naznačili, že objem emisie dlhopisov a veľkosť emitenta sú dôležité pri porovnávaní s dobrou povest'ou upisovateľa. Carbo-Valverde a kol. (2017) konštatujú, že dlhopisy emitované vo veľkých objemoch vydané veľkými emitentmi sú s väčšou pravdepodobnosťou umiestnené renomovanými upisovateľmi. Autori ďalej zistili, že kým objem emisie dlhopisov má väčší vplyv na pravdepodobnosť párovania s upisovateľom s vyššou reputáciou pre nefinančné spoločnosti, pre banky je relatívne rozhodujúcejšia veľkosť upisovateľa. Podľa štúdie Carbo-Valverde a kol. (2017) objem emisie dlhopisov mal len okrajový vplyv na pravdepodobnosť prístupu k renomovanému upisovateľovi. Tento vplyv bol až 1,7krát väčší pre nefinančné firmy ako pre banky, pričom tento rozdiel nebol pozorovaný pri veľkosti emitenta. Relatívna váha efektu veľkosti emitenta z hľadiska efektu objemu emisie bola väčšia skôr pre banky ako pre nefinančné firmy. Vplyv veľkosti emisie na pravdepodobnosť párovania sa zvyšuje u priemyselných firiem, keďže veľkosť podniku je významnejšia pre priemyselné firmy ako pre banky. Okrem toho autori Carbo-Valverde a kol. (2017), tvrdia, že vplyv splatnosti na pravdepodobnosť párovania s renomovaným upisovateľom bol väčší pre veľké banky ako pre veľké nefinančné spoločnosti, pričom rozdiel v pravdepodobnosti sa zvyšoval spolu so splatnosťou daného dlhopisu.

2 Cieľ práce

Primárnym cieľom predkladanej dizertačnej práce je vymedziť pomocou analýz postavenie a význam upisovateľov na primárnom dlhopisovom trhu.

Za účelom dosiahnutia uvedeného primárneho cieľa je potrebné splniť nasledujúce čiastkové ciele.

Čiastkový cieľ 1: Charakterizovať teoretické poznatky súvisiace so skúmanou problematikou doma a v zahraničí.

Pre naplnenie uvedeného čiastkového cieľa bude nutné vymedziť pojem primárny trh vo vzťahu k dlhopisom, popísať funkcie upisovateľov na primárnom dlhopisovom trhu, charakterizovať význam hrubého spreadu v procese emisie a definovať situácie kedy prichádza k preupísaniu emisie.

Čiastkový cieľ 2: Identifikovať vhodné parametre podnikových dlhopisov, ktoré majú súvis s hrubým spreadom a ich príprava na aplikačnú časť práce.

Za účelom dosiahnutia druhého čiastkového cieľa bude potrebné preskúmať a popísať základné parametre emisie ktoré sme sa rozhodli sledovať a máme ich obsiahnuté vo vzorke, identifikovať chýbajúce alebo redundantné hodnoty vo vzorke, určiť charakter jednotlivých premenných, definovať vhodné prediktory do modelu, vykonať štatistické testy vhodnosti využitia metód strojového učenia, prípadne iných, lineárnych metód v závislosti od charakteru skúmaných údajov.

Čiastkový cieľ 3: Identifikovať vedúcich upisovateľov na primárnom trhu dlhopisov.

Pre splnenie uvedeného podporného cieľa bude nutné analyzovať početnosť jednotlivých vedúcich upisovateľov v rámci skúmanej vzorky primárnych emisií na trhu s dlhopismi, vytvoriť triedy upisovateľov vo vzťahu k realizovaným emisiám a interpretovať zastúpenie jednotlivých upisovateľov, resp. syndikátu upisovateľov vo vzťahu k emitentovi a periodicite vzťahov.

Čiastkový cieľ 4: Identifikovať spoločné znaky a parametre emisií v sektore podnikových investičných dlhopisov.

Pre stanovený štvrtý čiastkový cieľ bude nevyhnutné posúdiť spoločné znaky jednotlivých emisií a preskúmať základné parametre, posúdiť spoločné znaky skúmaných

emisii vo vzťahu k parametrom súvisiacim s upisovateľom, resp. syndikátom upisovateľov a analyzovať asociácie medzi jednotlivými parametrami emisie.

Čiastkový cieľ 5: Zhodnotiť vplyv výberu vedúceho upisovateľa a konkrétneho syndikátu emisie na parametre výkonnosti emitovaných dlhopisov, najmä na hrubý spread a preupísanosť.

Za účelom splnenia vytýčeného čiastkového cieľa bude potrebné testovať vzťahy medzi hrubým spreadom a: základnými parametrami emisie, parametrami súvisiacimi s upisovateľom, regiónom a odvetvím priemyslu uskutočnenia emisie dlhopisov a preupísanosťou emisie.

Čiastkový cieľ 6: Interpretovať prínosy dosiahnutých výsledkov, definovať pravidlá a odporúčania, ako aj možnosti vyplývajúce z výsledkov pre ďalšie smerovanie výskumu.

Zdôvodnenie aktuálnosti stanoveného cieľa práce

Problematika financovania verejných ale aj súkromných investícií formou emisie dlhopisov je aktuálnou otázkou hneď z viacerých dôvodov. Jednotlivé podniky, samosprávy, inštitúcie, štáty ale aj spoločenstvá hľadajú spôsoby, ako naštartovať ekonomiku oslabenú vplyvom pandémie. Príkladom je program Európskej centrálnej banky PEPP (*Pandemic Emergency Purchase Programme*), ktorého úlohou je pomôcť európskym podnikom so zmiernením dopadov pandémie formou nakupovania podnikových dlhopisov za zvýhodnených podmienok na strane emitenta. Ďalšie aspekty, ktoré súvisia s využívaním financovania formou emisie dlhopisov na úrovni krajín aj podnikov sú napríklad: dosahovanie cieľov uhlíkovej neutrality a geopolitická kríza (Zhang a kol., 2022; Tuhkanen a Vulturius, 2022). V oblasti primárnych emisií bolo uskutočnených niekoľko štúdií, ktorých pozornosť je však venovaná skúmaniu vzťahov medzi spreadom pre upisovateľa a kreditným ratingom alebo ratingovou agentúrou (napr. Fang, 2005; Bajo a kol., 2016; Carbo-Valverde a kol. 2021). Investičné banky, resp. upisovatelia emisie nie sú prioritne cieľom výskumnej činnosti. Upisovatelia slúžia na primárnom dlhopisovom trhu ako sprostredkovateľ medzi dopytom po voľných finančných zdrojoch a ich ponukou. Na základe uvedených skutočností je dôležité analyzovať správanie a úlohy upisovateľov na primárnom trhu dlhopisov, rovnako aj, či reputácia upisovateľa môže ovplyvniť parametre emisie dlhopisov a výšku hrubého spreadu. Hrubý spread predstavuje výšku nákladov pre emitenta a z toho dôvodu považujeme za dôležité analyzovať parametre, ktoré výšku nákladov pre emitenta – podnik ovplyvňujú.

3 Metodika práce a metódy skúmania

Kapitola metodika práce a metódy skúmania má za úlohu charakterizovať objekt skúmania, predstaviť výskumné otázky práce, opísať pracovné postupy a použité matematicko-štatistické metódy, opísať skúmanú vzorku údajov a ich stručný opis. Následne je v kapitole uvedené overenie platnosti predpokladov pre navrhované metódy strojového učenia, ktoré bude nutné použiť k dosiahnutiu a naplneniu stanovených cieľov práce.

3.1 Charakteristika objektu skúmania

Objektom skúmania dizertačnej práce je primárny trh dlhopisov. Primárny trh dlhopisov označuje miesto, na ktorom sa odohráva prvotná verejná ponuka dlhových cenných papierov.

Aplikačná časť tejto práce, sa bude zaoberať skúmaním úloh upisovateľov v realizovaných prvotných verejných emisiách podnikových dlhopisov v období rokov 2012 až 2022. Výsledky dizertačnej práce budú založené na primárnej databáze údajov *Bond Radar* od firmy *Bloomberg*, ktorá zahŕňa záznamy o emitovaných dlhopisoch na globálnych trhoch. Premenné, s ktorými sa bude pracovať v analytickej časti, sú opísané v podkapitole 3.5, ktorá sa zaoberá opisom skúmaného vzorku.

3.2 Výskumné otázky práce

V analytickej časti práce sa budeme zameriavať na hrubý spread upisovateľa. Pri testovaní vzťahov vplývajúcich na výšku hrubého spreadu budeme sledovať dve skupiny parametrov.

Prvú skupinu parametrov budeme v práci nazývať ako *základné parametre*. Základné parametre budú zahŕňať vybrané premenné a indexy ktoré opisujú externé faktory vplývajúce na kondíciu finančného trhu ako aj splatnosť dlhopisu, udelený rating, objem, región a menu emisie.

Druhá skupina parametrov sa bude týkať vybraných premenných, ktoré slúžia na kvantifikáciu vplyvu upisovateľa, resp. syndikátu upisovateľov a vzťahov medzi upisovateľom a emitentom. V práci budeme tieto parametre nazývať ako parametre súvisiace s upisovateľom. Podrobnejší opis jednotlivých premenných bude uvedený v podkapitole 3.4.1 *Vytvorené premenné pre kvantifikáciu reputácie upisovateľov*.

Osobitnú pozornosť budeme venovať preupísanosti dlhopisov. Preupísanosť dlhopisu, vyjadruje dopyt ako násobok objemu emisie po skúmanej emisii pri výnosnosti stanovenej upisovateľom a bude tak možné vyjadriť možné podhodnotenie emisie. Jednou z výskumných otázok je, či na mieru preupísanosti majú významný vplyv parametre, ktoré súvisia s upisovateľom. Na základe uvedených skutočností je možné formulovať výskumné otázky pre analytickú časť práce:

Výskumná otázka 1: Existujú štatisticky významne rozdiely a vzťahy medzi hrubým spreadom upisovateľa IPO a sledovanými základnými parametrami dlhopisu?

Výskumná otázka 2: Existujú štatisticky významne rozdiely a vzťahy medzi hrubým spreadom upisovateľa IPO a parametrami súvisiacimi s upisovateľom (syndikátom) dlhopisu?

Výskumná otázka 3: Ako vplývajú externé faktory región emisie a odvetvie priemyslu emitenta na náklady na emisiu (hrubý spread)?

Výskumná otázka 4: Existuje na trhu podnikových dlhopisov štatisticky významný vzťah medzi hrubým spreadom a opakovanou emisiou emitenta pri využití služieb toho istého upisovateľa (syndikátu)?

Výskumná otázka 5: Vystupuje hrubý spread upisovateľa, alebo opakovaný vzťah medzi upisovateľom a emitentom ako jeden z dôležitých faktorov pri predikcii preupísanosti emisie?

Výskumná otázka 6: Ako a či vôbec má výber upisovateľa alebo syndikátu vplyv na preupísanosť emisie?

3.3 Pracovné postupy

Za účelom prípravy dát pre analytickú časť práce budeme nasledovať metodológiu CRISP-DM (angl. *Cross Industry Standard Process for Data Mining*), ktorá v súčasnosti patrí k najvyužívanejším metodologickým postupom v praxi pri analýze dát a ich príprave na simuláciu a modelovanie. Táto metodológia taktiež poskytuje užitočné informácie o spôsoboch riešenia problémov analýzy dát. Celá metodológia CRISP-DM pozostáva zo šiestich fáz: *I. Pochopenie skúmaného javu, II. Pochopenie dát súvisiacich so skúmaným javom, III. Príprava dát, IV. Modelovanie, V. Vyhodnotenie modelu a jeho výsledkov, VI.*

Implementácia modelu do praxe. (Moreira a kol., 2018) Pri aplikácii postupov metodiky CRISP-DM bude v práci potrebné vykonať nasledujúce kroky v súvislosti s prípravou dát pre analytickú časť práce. Pre výber výskumnej vzorky emisií na primárnom dlhopisovom trhu je potrebné brať na zreteľ vopred definované predpoklady, ako:

- kompletnosť atribútov emisie ako: emitent, objem, mena emisie, krajina emitenta;
- emisie dlhopisov, ktoré majú fixnú kupónovú sadzbu a finálnu dobu splatnosti;
- emisie, ktoré majú uvedený hrubý spread v bázičkých bodoch alebo percentách;
- uvedený kreditný rating emitenta aspoň od jednej z troch ratingových agentúr – Moody's, S&P alebo Fitch;
- uvedený upisovateľ, resp. upisovatelia príslušnej emisie.

V rámci fázy prípravy údajov bude potrebné vykonať konštrukciu nových atribútov – umelých premenných, ktoré budú vyjadrovať vlastnosti, resp. kombináciu skúmaného atribútu súvisiaceho s upisovateľom danej emisie, ako sú:

- počet vedúcich upisovateľov emisie;
- reputáciu upisovateľa – vyjadrenú umiestneným upisovateľom v rebríčku upisovateľov na základe: ročného upísaného objemu, počtu absolvovaných IPO;
- reputáciu syndikátu upisovateľov – vyjadrenú ako súčet ročného upísaného objemu syndikátu, ktorý sa podieľa na emisiách v určitom zložení;
- existenciu predchádzajúceho vzťahu upisovateľa a emitenta na primárnom dlhopisovom trhu.

3.3.1 Použité matematicko-štatistické metódy

V práci bude potrebné využiť matematicko-štatistické metódy za účelom dosiahnutia vopred definovaných cieľov opísaných v predchádzajúcej kapitole. Z matematicko-štatistických metód sa na základe povahy vstupných údajov bude v práci nutné použiť Kolmogorov-Smirnovov test na testovanie rozdelenia náhodného výberu zo súboru údajov, kde empirická distribučná funkcia F_n pre n nezávislých a identicky rozdelených (i.i.d.) usporiadaných pozorovaní X_i je definovaná ako: (Lilliefors, 1967)

$$F_n(x) = \frac{\text{počet prvkov vo vzorke} \leq x}{n} = \frac{1}{n} \sum_{i=1}^n 1_{(-\infty, x]}(X_i) \quad (1)$$

kde $1_{(-\infty, x]}(X_i)$ je indikačná funkcia rovná 1, ak $X_i \leq x$, inak sa rovná 0. Kolmogorov-Smirnovova štatistika pred danú kumulatívnu distribučnú funkciu $F(x)$ je:

$$D_n = \sup_x (x) - F(x) | \quad (2)$$

kde $\sup_x$ je suprémom množiny vzdialeností. Intuitívne, štatistika berie najväčší absolútny rozdiel medzi doma distribučnými funkciami vo všetkých hodnotách x .

Pri používaní regresných modelov bude nutné použiť dva typy regresie. Pre zhodnotenie platnosti predpokladov lineárnych vzťahov pôjde o generalizovaný lineárny model (GLM) podľa (Hutcheson, 2011). Vo všeobecnosti model GLM pozostáva z troch zložiek: závislej premennej Y , vysvetľujúcich premenných $x_1, x_2 \dots x_k$ a funkcie, ktorá ich spája (*angl. link function*). Tieto tri zložky tvoria základ zovšeobecneného lineárneho modelu, kde sa bežne označujú ako náhodná zložka, systematická zložka a funkcia prepojenia. Náhodná zložka predstavuje pravdepodobnostné rozdelenie, o ktorom sa predpokladá, že je základom závislej premennej. Systematická zložka je pevná štruktúra vysvetľujúcich premenných, zvyčajne charakterizovaná lineárnou funkciou:

$$\alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \quad (3)$$

Funkcia prepojenia je funkciou, ktorá mapuje systematickú zložku na náhodnú zložku. Táto funkcia môže byť jedna z identít pre normálne rozdelené náhodné zložky alebo jedna z viacerých nelineárnych väzieb, keď náhodná zložka nie je normálne rozdelená.

V analytickej časti práce bude nutné využiť aj regresiu podľa (Huber, 1973). Všeobecne možno popísať daný regresný model ako L2-regulárny lineárny regresný model, ktorý je odolný voči odľahlým hodnotám. Huberov regresor optimalizuje stratu štvorcov pre vzorky, v ktorých $|\frac{(y - X_w - c)}{\sigma}| < \varepsilon$ a absolútnu stratu pre vzorky, v ktorých $|\frac{(y - X_w - c)}{\sigma}| > \varepsilon$, pričom optimalizovanými parametrami sú koeficienty modelu w , konštanta c a stupnica σ . Parameter σ zabezpečuje, že ak sa y škáluje nahor alebo nadol určitým faktorom, nie je potrebné meniť škálu ε , aby sa dosiahla totožná robustnosť. Huberová stratová funkcia má tú výhodu, že nie je výrazne ovplyvnená odľahlými hodnotami, ale ani ich vplyv úplne neignoruje. (Pedregosa et al., 2011)

3.4 Opis skúmanej vzorky

Základná vzorka údajov bude obsahovať zoznam dlhopisov vydaných v období rokov 2012 – 2022. Jednotlivé parametre uvedené nižšie budú čerpané z databázy Bond

Radar od spoločnosti *Bloomberg*, v zátvorke je uvedený anglický ekvivalent daného atribútu. Vysvetlený význam jednotlivých premenných je dostupný v dokumentácii na internetovej stránke poskytovateľa databázy. Motivácia ohľadom zaradenia nižšie spomenutých parametrov dlhopisov pochádza z predchádzajúcich štúdií (Fang, 2005; Naeem et al., 2021; Wang et al., 2022)

Dátum (*date*) intervalová premenná v intervale rokov 2012 až 2022 v závislosti od dátumu emisie. Emitent (*issuer*) diskretná premenná nominálneho typu popisujúca názov emitenta dlhopisov. Mena (*currency*) diskretná premenná nominálneho typu nadobúdajúca hodnoty v závislosti od meny, v ktorej boli dlhopisy emitované. Objem emisie v miliónoch amerických dolárov (*volume_usd*) spojitá premenná vyjadrujúca objem emisie v mene emisie. Kupón (*coupon*) spojitá premenná nadobúdajúca hodnotu kupónovej sadzby priradenej pre danú emisiu. Typ kupónu (*coupon_type*) diskretná premenná binárneho typu opisujúca, či je prislúchajúci kupón dlhopisu fixný alebo plávajúci. Táto premenná bude použitá na prvotnú identifikáciu dlhopisov s fixnou kupónovou sadzbou, nakoľko tieto dlhopisy budú predmetom analýzy. Splatnosť dlhopisu (*maturity_years_rounded*) diskretná premenná ordinálneho typu označujúca konkrétny dátum, ku ktorému je daný dlhopis splatný, matematicky zaokrúhlená na celé roky. Re-Offer (*reoffer*) spojitá premenná, ktorá vyjadruje percentuálny podiel emisie, ktorý bol upisovateľ schopný umiestniť medzi investorov. Túto premennú si možno predstaviť ako cenu opätovnej ponuky za ktorú upisovateľ alebo syndikát emisie opätovne predá dlhopisy IPO investorom po ich odkúpení od emitenta. Hrubý spread (*UW_spread(%)*), spojitá premenná vyjadrujúca výšku hrubého spreadu – poplatku upisovateľovi od emitenta v percentách z nominálnej hodnoty emisie. Moody's, S&P, Fitch (*moody's_rating*, *s&p_rating*, *fitch_rating*) diskretná premenná ordinálneho typu, ktorá nadobúda hodnoty v závislosti od ratingu, v prípade ak bol danej emisii priradený od konkrétnej ratingovej agentúry. Za účelom synchronizácie ratingov udelených od rozličných agentúr budú ratingy transformované na úroveň rizika (Tab. 1). Ranking (*ranking*) diskretná premenná nominálneho typu vyjadrujúca pásmo investičného pásma pre daný dlhopis. Región (*region*) diskretná premenná nominálneho typu, ktorá vyjadruje región z ktorého emitujúci podnik pochádza. Krajina (*country*) diskretná premenná nominálneho typu vyjadrujúca krajinu pôvodu emitenta. Odvetvie (*category*) diskretná premenná nominálneho typu, ktorá špecifikuje odvetvie v rámci daného sektora. Pasívny Lead – upisovateľ (*passive_lead*) diskretná premenná nominálneho typu, ktorá obsahuje údaj o investičnej banke, ktorá v danej emisii vystupovala na pozícii pasívneho

upisovateľa emisie. Štatistika preupísanosti emisie (*os_rate*) spojená premenná popisujúca preupísanosť pozorovanej emisie dlhopisu, vyjadrujúca koľkokrát bola daná emisia preupísaná. Zelený dlhopis (*green*) diskretná premenná binárneho typu označujúca, či daná emisia spĺňa kritéria pre kategóriu označenia „zelený dlhopis“. Udržateľný dlhopis (*sustainable*) diskretná premenná binárneho typu opisujúca, či daná emisia napĺňa znaky financovania za cieľom udržateľného rozvoja. Zmena kontroly (*COC*) diskretná premenná binárneho typu, ktorá obsahuje informáciu, či daná emisia obsahuje doložku o zmene kontroly, ktorá je navrhnutá tak, aby chránila investorov pred tým, aby spoločnosť emitujúca dlhopisy bola prevzatá iným subjektom počas životnosti dlhopisu, čím sa mení celkový rizikový profil, ku ktorému sa pôvodní investori dlhopisov prihlásili. Predčasné splatenie (*MWC*) diskretná premenná binárneho typu popisujúca existenciu klauzule dlhopisu, ktorá umožňuje emitentovi predčasne splatiť zostávajúci dlh. Lead1 ... Lead29 – diskretná premenná nominálneho typu, ktorá obsahuje oficiálnu skratku investičnej banky, ktorá bola upisovateľom emisie, alebo súčasťou syndikátu upisovateľov.

Okrem vyššie uvedených premenných dostupných z databázy *Bond Radar*, bude pri analýze vhodné použiť aj ukazovatele, ktoré popisujú situáciu na trhu. Na opis kondície trhu bude použitý index VIX, ktorý je mierou očakávanej volatility indexu S&P 500, mnohokrát použitý ako referenčný index amerického akciového trhu. Index VIX sa často označuje ako „index strachu“, pretože má tendenciu rásť v obdobiach napätia a neistoty na trhu a klesať v obdobiach stability a dôvery na trhu. Index výkonnosti európskych investičných podnikových dlhopisov EAGG.PA možno použiť na posúdenie celkového trendu a nálady na trhu s dlhopismi denominovanými v eurách, ako aj výkonnosti spoločností a organizácií. Ďalším parametrom, ktorý slúži na zachytenie kondície trhu je index VCIT. Index VCIT je používaný ako skrátený názov pre *Vanguard Intermediate-Term Corporate Bond ETF*. Je to burzový fond, ktorý sleduje výkonnosť strednodobých podnikových dlhopisov v Spojených štátoch. Jeho hodnota sa mení v závislosti od výkonu tohto trhu a poskytuje investorom informácie o aktuálnej situácii a sentimente na trhu.

3.4.1 Vytvorené premenné pre kvantifikáciu reputácie upisovateľov

Za účelom kvantifikácie reputácie jednotlivých upisovateľov bude potrebné vytvoriť parametre, ktoré opisujú ich postavenie na trhu podnikových dlhopisov. V rámci kvantifikácie reputácie budeme postupovať podľa predchádzajúcich štúdií (Hu et al., 2021; Arora a Singh, 2020; Teja, 2021). Prvou vytvorenou premennou bude parameter *RANK*,

ktorý vyjadrí pozíciu konkrétneho upisovateľa voči ostatným upisovateľom, ak budú usporiadaní vzostupne od 1, 2, ... n , v závislosti od počtu IPO na ktorých sa daný upisovateľ zúčastnil za kalendárny rok. Daný parameter sa teda môže pri jednotlivých upisovateľoch líšiť v závislosti od roku uskutočnenia IPO. Ďalšou vytvorenou premennou bude parameter *SHARE*, ktorý bude mať za úlohu vyjadriť trhovú podiel upisovateľa za kalendárny rok na primárnom trhu podnikových dlhopisov, rovnako pri vzostupnom usporiadaní ako v prípade parametra *RANK*. Následne bude reputáciu upisovateľov potrebné kategorizovať do skupín podľa spoločných znakov reputácie. V tomto prípade budeme postupovať tak, že upisovateľov kategorizujeme do kvartilov (*QUARTILE*), v ktorých budú jednotliví upisovatelia v zaradení do príslušného kvartilu v každom roku v závislosti od objemu emisií upísaných počas jedného roka. Pre podrobnejšie členenie bude potrebné vytvoriť parameter, ktorý rozlíši, či sa daný upisovateľ sa v danom roku umiestnil v závislosti od upísaného objemu v TOP5 (na prvom až piatom mieste), TOP10 (na šiestom až desiatom mieste), TOP15 (na jedenástom až pätnástom mieste), TOP20 (na šestnástom až dvadsiatom mieste), alebo mimo TOP20 (umiestnenie horšie ako dvadsiaty). Ďalšími vytvorenými premennými sú premenné, ktoré sa týkajú syndikátov ako takých. Pre každý syndikát bude potrebné vytvoriť jedinečné identifikačné číslo, aby bolo možné identifikovať všetky jedinečné zoskupenia. Tieto jedinečné zoskupenia bude potrebné sledovať každý jeden rok, aby bolo možné vytvoriť premenné *RANK*, *SHARE*, *QUARTILE*, *UW_TOP* spolu s príponou *_syndicate*, ktoré označujú, aké je ročné umiestnenie, podiel, kvartil a percentuálne umiestnenie upisovateľov pozorovaného syndikátu v danom roku, ktorú upisoval. V záujme vyjadriť aj absolútnu početnosť výskytu syndikátu v procese upisovania bude potrebné vytvoriť parameter vyjadrujúci danú početnosť ako *syndicate_count*. Nakoľko je zloženie syndikátov v mnohých prípadoch naozaj rôznorodé, ďalším vytvoreným parametrom bude *BestRank_syndicate*, ktorý bude obsahovať informáciu o najlepšie postavenom upisovateľovi v rámci pozorovaného syndikátu na základe upísaného objemu počas kalendárneho roku. Ku všetkým vytvoreným premenným kvantifikujúcich reputáciu upisovateľa a syndikátu bude potrebné vytvoriť oneskorenú premennú, ktorá bude vyjadrovať daný parameter s ročnou oneskorenou hodnotou, označenie bude s príponou *_lagged*. Dôvodom pre vytvorenie oneskorenej premennej je zachytenie javu, či sa reputácia upisovateľa prejaví v rozhodnutiach emitenta, keďže priemerná doba prípravy emisie dlhopisov sa pohybuje v intervale 3 až 12 mesiacov.

Podobne ako v prípade štúdií (Carbo-Valverde a kol., 2021, Dick-Nielsen a kol., 2021; Ottonello a kol., 2022) bude v práci nutné kvantifikovať aj počet vzťahov medzi upisovateľom a emitentom v priebehu roka *rel_issuer_uw*, počet vzťahov medzi emitentom a príslušným syndikátom upisovateľov *rel_issuer_syndicate* ako aj počet emisií, ktoré emitent v priebehu kalendárneho roka absolvoval. Za účelom kvantifikácie výskytu emitenta na primárnom trhu podnikových dlhopisov bude potrebné vytvoriť premennú, ktorá bude nositeľom informácie, či sa jedná o absolútne prvú pozorovanú emisiu emitenta vo vzorke *issuer_first_appearance*. V prípade niektorých emitentov bude možné pozorovať opakovaný výskyt na primárnom dlhopisovom trhu. S cieľom kvantifikácie uvedeného javu bude vytvorená premenná *relation_year*, ktorá bude mať ordinálny charakter. S hodnotou 1 budú označené tie emisie, ktorých emitenti sa na trhu vyskytli iba jedenkrát v priebehu roka. Hodnota 2 bude značiť, že daný emitent sa v priebehu roka emitoval dva až trikrát. Hodnota 3 bude výskyt emitenta v počte štyri až päťkrát v priebehu roka. Hodnota 4 bude značiť tie prípady, keď sa emitent na trhu v priebehu roka vyskytne viac ako päťkrát. Dôvodom pre popísané delenie je rozdelenie, ktoré nasleduje kvartily početnosti výskytu emitenta na trhu v priebehu roka. Ostatným vytvoreným parametrom bude spojitá premenná *issuer_appear*, ktorá sa pre každého z identifikovaných emitentov mení počas celého sledovaného obdobia v závislosti od poradia emisie uskutočnenej daným emitentom od 1.1.2012 do 31.12.2022.

3.5 Hodnotenie platnosti predpokladov

V nasledujúcej časti práce bude cieľom preskúmať, či sú všetky predpoklady, ktoré sú nutné pri vytváraní modelov s využitím metód strojového učenia platné. Ak by boli predpoklady neplatné, malo by to vplyv na presnosť a spoľahlivosť výsledných modelov. Ďalším cieľom tejto podkapitoly bude verifikovať, či závislá premenná hrubý spread upisovateľa pochádza z normálneho rozdelenia. Ak áno, bolo by možné použiť parametrické štatistické metódy, kým v prípade, že závislá premenná nepochádza z normálneho rozdelenia, bude nutné použiť neparametrické štatistické metódy na analýzu vzťahov, v ktorých je táto premenná skúmaná.

3.5.1 Deskriptívna štatistika analyzovaných vzoriek

Základom pre výskum bola základná vzorka všetkých údajov, ktoré spĺňali vyššie uvedené predpoklady. **Tabuľka 1** uvádza deskriptívnu štatistiku základnej skúmanej

vzorky údajov. Následne sme z tejto vzorky vytvorili podvzorky, v rámci ktorých sme vykonávali určité špecificky orientované testovania.

Tieto jednotlivé vzorky, ktoré bude potrebné v práci analyzovať sa od seba odlišujú. Vzorka označená ako ‘IG+HY’ označuje základnú vzorku, v ktorej sa nachádzajú podnikové dlhopisy zo všetkých kategórií rankingu, ako aj dlhopisy bez udeleného ratingového ohodnotenia. Vzorka označená ako ‘IG’ zahŕňa iba podnikové dlhopisy s rankingom označujúci investičný dlhopis. Dlhopisy ostatného rankingu (Crossover, Neinvestičné a bez rankingu) sú z tejto vzorky vylúčené. Dôvodom pre uvedenú modifikáciu boli štatisticky významné rozdiely v skúmaných vzorkách.

Tabuľka 1 Opisná štatistika základnej skúmanej vzorky údajov

Premenná	N	Min	Max	$\bar{x}$	σ	1.kvartil	3.kvartil
Hrubý spread (%)	19731	0.05	30.82	4.49	3.75	1.95	5.95
Objem (v mil. USD)	19731	7.40	149823	716	533	400	856
Splatnosť dlhopisu v rokoch	19731	1	1011	10.46	10.90	5	10
Rating: Moodys	17508	1	19	9.02	3.6	7	11
Rating: S&P	17862	1	20	8.87	3.38	7	10
Rating: Fitch	7799	1	20	8.39	2.46	7	10
Miera preupísanosti	1699	0	24.86	0.48	1.66	0	0

Zdroj: Vlastné spracovanie.

Vzorka ‘IG_out’ podobne ako vzorka ‘IG’ obsahuje iba investičné dlhopisy, no v tomto prípade boli zo vzorky odstránené všetky pozorovania, v ktorých boli identifikované extrémne hodnoty v spojitých premenných: Hrubý spread upisovateľa, Objem emisie (USD), Splatnosť dlhopisu v rokoch, Reoffer. Na identifikáciu extrémnych hodnôt bol použitý prístup 1.5-násobku interkvartilového rozpätia. Vzorku sme týmto spôsobom upravili o 3869 pozorovaní, ktoré uvedené podmienky nespĺňali. Pre každú zo vzoriek uvedených v **Tabuľke 2** sme testovali rozdelenie závislej premennej a teda, či náhodné vybrané hodnoty hrubého spreadu pochádzajú z normálneho rozdelenia pravdepodobnosti.

Ani jedna zo spomínaných vzoriek na základe Kolmogorov-Smirnov testu závislej premennej nespĺňa podmienky normality, *p-hodnoty* vykonaných testov nedosiahli

stanovenú hranicu $\alpha = 0.05$, ako je uvedené v **Tabuľke 3**. Z toho dôvodu nie je možné prijať nulové hypotézy formulované v **tabuľke 3** o rozdelení hrubého spreadu a teda, že pravdepodobnosť náhodného výberu závislej premennej nepochádza z normálneho rozdelenia.

Tabuľka 2 Opisná štatistika závislej premennej – Hrubý spread upisovateľa

Vzorka		IG+HY	IG	IG_out
N		19731	15090	11198
Priemer		4.492	2.898	2.559
95% Interval spoľahlivosti	dolná hranica	4.440	2.87	2.535
	horná hranica	4.544	2.926	2.584
Medián		3.1	2.5	2.3
Rozptyl		13.974	3.074	1.778
Štandardná odchýlka		3.738	1.753	1.333
Minimum		0.05	0.05	0.05
Maximum		30.82	23.62	6.56
Medzikvartilové rozpätie		3.950	1.95	1.81
Šikmosť		1.71	1.919	0.764
Špicatosť		3.142	8.506	0.029

Zdroj: Vlastné spracovanie.


Podľa histogramu, ktorý uvádza početnosť rozdelenia hrubého spreadu upisovateľa, zobrazeného na **grafe 1** a údajov o závislej premennej z **tabuľky 2** bolo možné potvrdiť, že rozloženie pozorovaných hodnôt má pozitívnu šikmosť, čo vyjadruje, že väčšina hodnôt sa nachádza na ľavej strane grafu (pri nižších hodnotách hrubého spreadu). Priemer u pozorovaného rozdelenia je väčší ako medián a toto rozdelenie má tzv. dlhé konce na pravej strane t.j. väčšie množstvo emisií než u normálneho rozdelenia, ktoré majú vysoké hodnoty hrubého spreadu. Histogram uvedený na grafe 1 má nízku hodnotu špicatosti, čo indikuje, že dáta sú pomerne rovnomerne rozmiestnené.

Tabuľka 3 Kolmogorov-Smirnovov test rozdelenia závislej premennej

Nulová hypotéza:	Vzorka	Štatistika	p-hodnota	Rozhodnutie o H0:
Hrubý spread upisovateľa pochádza z normálneho rozdelenia	IG+HY	0.175	.000	zamietame
Hrubý spread upisovateľa pochádza z normálneho rozdelenia	IG	1	.000	zamietame
Hrubý spread upisovateľa pochádza z normálneho rozdelenia	IG_out	0.776	.000	zamietame

Zdroj: Vlastné spracovanie.

Graf 1 Histogram rozdelenia hrubého spreadu upisovateľa



Zdroj: Vlastné spracovanie

Za účelom výberu vhodných metód pre testovanie vzťahov jednotlivých parametrov dlhopisov, ako aj vplyv upisovateľa na hrubý spread sme uskutočnili Ramseyho RESET (*Regression Equation Specification Error Test*) test spolu s využitím generalizovaného lineárneho modelu (GLM), keďže GLM umožňuje testovať aj iné rozdelenia distribučných funkcií ako normálne rozdelenie. Po použití GLM bol RESET test použitý na overenie funkčnej formy modelu a jeho korektnosti. Výsledky RESET testu nám naznačili, že vhodnosť použitia daného modelu so špecifikovanými parametrami nepredstavuje vhodný

typ, nakoľko *p*-hodnoty jednotlivých nezávislých premenných dosiahli nízke hodnoty, s výnimkou premenných *reoffer*, *num_leads* (počet upisovateľov podieľajúcich sa na emisii) a *RANK_synd* (poradový priemer syndikátu). F-štatistika RESET testu bola 17.998 s *p*-hodnotou = 0.000, na základe čoho sme mohli zamietnuť hypotézu, že model má správnu funkčnú formu. Rovnako tak na základe výsledkov RESET testu sme mohli zamietnuť hypotézu, že na odhad parametrov emisie a hrubého spreadu upisovateľa je možné využiť lineárny model. Na základe daných výsledkov sme sa rozhodli na testovanie vzťahov použiť v analytickej časti neparametrické metódy a rozhodovacie stromy.

3.6 Rozhodovacie stromy

Na základe výsledkov pri hodnotení platnosti predpokladov, budeme v práci používať techniky strojového učenia a to rozhodovacie stromy. Dôvodom pre výber uvedených techník sú skutočnosti, že rozhodovacie stromy môžu fungovať dobre aj vtedy, ak sú porušené predpoklady pre využitie parametrických metód (Gupta, 2017). Ďalšou výhodou je, že na rozdiel od parametrických modelov nemajú rozhodovacie stromy predpoklady o základnom rozdelení údajov a nie je potrebné brať do úvahy monotónne transformácie, napríklad logaritmy (Gepp a kol., 2015). Použité budú rozhodovacie stromy s využitím metód, resp. algoritmov XGBOOST, C5.0 a CHAID. Uvedené metódy budú aplikované použitím programovacieho jazyka *Python* v prostredí *Google Colab* s využitím knižníc *numpy*, *pandas*, *matplotlib*, *sklearn* a *stats*. Ďalšími nástrojmi použitými na spracovanie a vyhodnotenie údajov budú štatistické aplikácie *IBM SPSS Statistics* 26 a *IBM SPSS Modeler* 18.3.

3.6.1 XGBoost regresný strom

V analýze výsledkov bude primárne použitý algoritmus *Xtreme Gradient Boosting* (XGBoost). Model XGBoost prekonal modely umelých neurónových sietí aj regresie podporných vektorov (angl. *Support Vector Machine*, SVM) v štúdiu Osmana a kol. (2021). Podobné závery vyslovili aj v štúdiu Nguyen a kol. (2020), kde všetky tri použité metódy strojového učenia (XGBoost, umelé neurónové siete, SVM) poskytli presné výsledky, avšak metóda XGBoost bola vyhodnotená robustnejšia, menej náročnejšia na výpočtový výkon a aj ako najpresnejšia na základe nameranej chyby v predikcii. XGBoost pozostáva z nasledujúcich komponentov:

- Koreňový uzol: Koreňový uzol obsahuje závislú alebo cieľovú premennú.

- Rodičovský uzol: Algoritmus rozdelí cieľovú premennú do dvoch alebo viacerých kategórií. Tieto kategórie sa nazývajú rodičovský uzol alebo nadradený uzol.
- Podradený uzol: Kategórie nezávislých premenných, ktoré sa nachádzajú pod kategóriami rodičov v strome analýzy XGBoost, sa nazývajú podriadený uzol.
- Koncový uzol: Posledné kategórie stromu analýzy XGBoost sa nazývajú koncový resp. terminálny uzol. V strome analýzy XGBoost je kategória, ktorá má hlavný vplyv na závislú premennú, na prvom mieste a najmenej dôležitá kategória je na poslednom mieste.

Algoritmus XGBoost využíva najmä regularizačné parametre, ktorými sú hyperparametre, kontrolujúce silu regularizácie v modeli strojového učenia. Používajú sa na obmedzenie pretrénovania modelu a zlepšenie jeho schopnosti generalizácie na nové neznáme dáta. V kontexte XGBoost regresora sú dva hlavné typy regularizačných parametrov:

- L1 (Lasso) regularizácia – Kontroluje silu L1 regularizácie a je riadený hyperparametrom γ . L1 regularizácia sa používa na indukciu riedkych váh, čo môže pomôcť s výberom príznakov a elimináciou nepotrebných funkcií.
- L2 (Ridge) regularizácia – Kontroluje silu L2 regularizácie a je riadený hyperparametrom λ . L2 regularizácia sa používa na zabránenie pretrénovania tým, že obmedzuje hodnoty váh a znižuje ich celkovú veľkosť. Toto môže viesť k zlepšeniu výkonu modelu na nových dátach.

Oba typy regularizácie sa používajú spoločne a môžu pomôcť optimalizovať výkon XGBoost regresora. Hlavnou výhodou je, že vďaka týmto parametrom sa môže zabrániť pretrénovaniu modelu a zlepšiť sa jeho generalizácia na nové neznáme dáta. (Chen a Guestrin, 2016)

Algoritmus XGBoost je pokročilý systém rozhodovacích stromov, využívajúcich princíp vylepšovania (*angl. Boosting*). Princíp boostingu je flexibilnejší pri implementácii nelineárnych a krížových transformácií na vstupných funkciách. Konkrétne sú odolné voči odľahlým hodnotám, škálovateľné a vďaka svojej hierarchickej štruktúre dokážu prirodzene modelovať nelineárne rozhodovacie hranice. Tento druh modelu je vhodný na spracovanie

numerických prvkov a kategoriálnych prvkov s desiatkami kategórií (Zhou a kol., 2019). Boosting je metóda na transformáciu slabého klasifikátora na silný klasifikátor, ktorého funkčný model je nadriadený. (Ma a kol., 2021)

$$D = \{(x_i, y_i)\} (|D| = n, x_i \in \mathbb{R}) \quad (4)$$

$$\hat{y}_i = \phi(x_i) = \sum_{k=1}^K f_k(x_i), f_k \in F \quad (5)$$

kde D predstavuje súbor údajov, m rozmerov a množstvo je n . Konkrétne, každý strom je stromový model, ktorý môže vyjadriť nasledovne: (Ma a kol., 2021)

$$F = \{f(x) = w_{q(x)}\} (q: \mathbb{R}^n \rightarrow T, \omega \in \mathbb{R}^T). \quad (6)$$

kde $q(x)$ predstavuje vzťah mapovania medzi vzorkou x a listovými uzlami modelu stromu a ω je predpovedaná hodnota použitá na priradenie k vzorkám patriacim k príslušným listovým uzlom modelu stromu. Od druhého kola sa pre každé tréovanie zadáva rezíduum medzi predikovanými a skutočnými hodnotami z posledného kola. Výsledkom posledného listového uzla je tiež predikcia rezídua. Aby sa zabránilo nadmernému prispôsobeniu, objektívna funkcia XGBoost sa skladá zo stratovej funkcie a člena komplexnosti. Komplexnosť pozostáva z počtu listov a regulárnosti L2: (Chen a Guestrin, 2016)

$$L(\phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k), \quad (7)$$

kde $\Omega(f) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2$ môže generovať minimálnu hodnotu, pretože člen straty a člen zložitosti sú konvexné funkcie. Lepšie sa to dá pochopiť tak, že ω je rezíduum k skutočnej hodnote a pridanie L2 regularity ω do cieľovej funkcie môže zabrániť nadmernému prispôsobeniu. Keď je cieľová funkcia určená, prejde sa k procesu tréovania. Pre každý proces iterácie sa tréovanie účelovej funkcie stromu možno zapísať nasledovne: (Chen a Guestrin, 2016)

$$L^{(t)} = \sum_i l(y_i, \hat{y}_i^{t-1}) + f_t(x_i) + \Omega(f_t) \quad (8)$$

Vstupom je predpovedaná hodnota po $(t-1)$ -tom kole a skutočná hodnota sa použije na priradenie k rezíduu. V tomto vzorci sa na získanie tvaru stratovej funkcie vykonáva aproximácia Taylorovým rozkladom druhého rádu: (Chen a Guestrin, 2016)

$$L^{(t)} \approx \sum_{i=1} l(y_i, \hat{y}_i^{t-1}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) + \Omega(f_t), \quad (9)$$

kde $g_i = \frac{\partial}{\partial \hat{y}} l(y_i, \hat{y}^{(t-1)})$, $h_i = \frac{\partial^2}{\partial \hat{y}^2} l(y_i, \hat{y}^{(t-1)})$. Následne je po sérii výpočtov najmenšia účelová funkcia ω nasledovná: (Chen a Guestrin, 2016)

$$w_j^t = -\frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (10)$$

Na predpovedanie výsledku používa XGBoost aditívne funkcie v tvare: (Chen a Guestrin, 2016)

$$\bar{y}_i = y_i^0 + \eta \sum_{k=1}^M f_k(X_i) \quad (11)$$

kde $\bar{y}_i$ je predpovedaný výsledok pre i -tú vzorku, ktorej vektor znakov je X_i . M je počet odhadov a každý odhad f_k (z k od 1 do M) zodpovedá nezávislej stromovej štruktúre. y_i^0 je počiatočný odhad, ktorý je priemerom nameraných hodnôt v trénovacej množine. η je miera učenia (*angl. learning rate*), ktorá pomáha plynulo zlepšovať model pri pridávaní nového stromu a zabrániť nadmernému prispôsobeniu – pretrénovaniu (*angl. overfitting*). Tréninový proces algoritmu XGBoost je realizovaný aditívnym spôsobom. Vzhľadom na rovnicu (11) sa v k -tom kroku pridá do modelu k -ty odhad a k -ty predpovedaný výsledok $\bar{y}_i^k$ sa vypočíta z predpovedanej hodnoty v predchádzajúcom kroku $\bar{y}_i^{(k-1)}$ a odhadu f_k dodatočného k -tého odhadu ako: (Brownlee, 2016)

$$\bar{y}_i^k = \bar{y}_i^{(k-1)} + \eta f_k \quad (12)$$

kde f_k je definované váhami listov, ktoré sa nájdu minimalizáciou účelovej funkcie k -tého stromu, ktorá je definovaná ako: (Brownlee, 2016)

$$obj = \gamma T + \sum_{j=1}^T \left[G_j \omega_j + \frac{1}{2} (H_j + \lambda) \omega_j^2 \right] \quad (13)$$

kde T je počet listov k -tého stromu a ω_j z j od 1 do T sú váhy listov. λ a γ sú regularizačné parametre, ktoré riadia jednoduchosť štruktúry stromu, aby sa zabránilo nadmernému prispôsobeniu trénovaného modelu. Parametre G_j a H_j , ktoré sú celkovými sumami vzoriek priradených k j -tému listu prvého a druhého gradientu stratovej funkcie. K -ty strom sa vytvorí rozdelením listov počnúc počiatočným listom. Takýto postup sa realizuje maximalizáciou parametra zosilnenia (boosting), ktorý je definovaný vzťahom: (Brownlee, 2016)

$$boosting = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (14)$$

kde G_L a H_L sú priradené k ľavému listu a G_R a H_R sú priradené k pravému listu po rozdelení. Rozdelenie je akceptované, ak je parameter zosilnenia > 0 . Preto zvýšenie regularizačných

parametrov λ a γ zníži parameter zosilnenia, čo umožní vyhnúť sa zložitosti rozdelenia listov, t. j. zachovať jednoduchú štruktúru stromu. Takýmto spôsobom je pravdepodobné znížiť schopnosť modelu prispôbiť sa údajom, na ktorých je trénovaný.

3.6.2 Klasifikačný strom C5.0

Algoritmus algoritmu C5.0 je nástupcom predchádzajúcej verzie C4.5. V porovnaní s predchodcom je rýchlejší, efektívnejší vo využívaní operačnej pamäte výpočtovej techniky, vytvára menšie (nie tak rozsiahle) rozhodovacie stromy v porovnaní súbory majú nižšiu chybovosť a vo všeobecnosti presnejšiu mieru klasifikácie jednotlivých prípadov (Pandya, 2015; Revathy a Lawrance, 2017). Algoritmus C5.0 používa na meranie koncept informačnej entropie. Entropia vzorky údajov ukazuje, ako zmiešané sú hodnoty jednotlivých tried. v Takom prípade minimálna hodnota 0 znamená, že vzorka je úplne homogénna, zatiaľ čo hodnota 1 znamená maximálnu mieru heterogenity. Nech S je náhodná premenná nadobúdajúca hodnoty $s_i, i \in \{1, \dots, n\}$ a funkciou hustoty pravdepodobnosti p . Definícia entropie je špecifikovaná ako: (Quinlan, 2014)

$$H(S) := \sum_{i=1}^c -p(s_i) \log_2(p(s_i)), \quad (15)$$

kde pre daný segment údajov (S) výraz c označuje počet rôznych úrovní triedy a p_i označuje podiel hodnôt spadajúcich do úrovne triedy i . Výraz $-\log_2(p(s_i))$ súvisí s počtom úrovní v rozhodovacom strome potrebných na určenie výsledku realizácie s_i náhodnej premennej S . Ak $\log_2\left(\frac{1}{p(s_i)}\right) = -\log_2(p(s_i))$, kde $q(s_i)$ predstavuje počet rozhodovacích uzlov na jednej konkrétnej úrovni rozhodovacieho stromu, $\log_2(q(s_i))$ vyjadruje počet úrovní. Funkcia entropie $H(S)$ uvedená vyššie spĺňa:

- $H(S)$ je spojitá v $p(s_i), i \in \{1, \dots, n\}$.
- Ak $p(s_i) = 1/n$ pre $i = 1, \dots, n$, potom $H(S)$ je monotónne rastúca funkcia n .
- $H(S)$ je aditívna, $H(S, Q) = H(S) + H(Q)$ pre akúkoľvek vybranú hodnotu dvoch náhodných nezávislých premenných S a Q .

Algoritmus C5.0 sa stále musí rozhodnúť, pri ktorom prvku sa má rozdeliť. Na tento účel používa algoritmus entropiu na výpočet zmeny homogenity vyplývajúcej z rozdelenia každého možného znaku. Tento výpočet sa označuje ako informačný zisk (*angl. Information gain*). Čím vyšší je informačný zisk, tým vhodnejší je prvok pri vytváraní homogénnych skupín pri rozdelení daného prvku.

Informačný zisk pre znak F sa vypočíta ako rozdiely medzi entropiou v segmente pred rozdelením (S_1) a entropiou vyplývajúcou z rozdelenia (S_2):

$$\text{Informačný zisk } (F) = \text{Entropia}(S_1) - \text{Entropia}(S_2) \quad (16)$$

Vzhľadom na realizáciu náhodnej premennej S , budeme predpokladať, že s každým pozorovaním je spojených N atribútov $\{a_i\}_{i=1}^N$, kde $a_i = a_i(S)$ pre všetky $i = 1, \dots, N$. To dáva pozorovanie do stavu $(s_i, a_1(s_i), \dots, a_N(s_i))$, kde každý atribút a_i je sám o sebe realizáciou náhodnej premennej.

Nech $\{s_i\}_{i=1}^n$ je množina možných výsledkov náhodnej premennej S s entropiou $H(S)$. Nech A predstavuje množinu všetkých prípustných hodnôt N -tice $(a_1(s_i), \dots, a_N(s_i))$, $i = 1, \dots, n$. Pre každú funkciu a_i , nech A_i vyjadruje množinu možných výsledkov a_i . Pre množinu realizácií $\dot{S}$ náhodnej premennej S a atribútov A : (Mitchell, 1997)

$$IG(\dot{S}, A_i) = H(\dot{S}) - \sum_{a \in A_i} \frac{|\dot{S}_a|}{|\dot{S}|} H(\dot{S}_a), \quad (17)$$

kde $\dot{S}_a := \{s \in \dot{S} | a_i(s) = a\}$, vyjadruje informačný zisk pre rozdelenie S na atribúte $a_i(s)$ a $|\cdot|$ vyjadruje kardinálnosť. Informačný zisk popisuje zníženie entropie pri rozdelení množiny realizácií do dvoch samostatných množín na základe atribútu. Zníženie entropie v tomto zmysle je, keď je celková entropia množiny vyššia, ako je celková entropia dvoch podmnožín vytvorených daným rozdelením.

Jednou z častých komplikácií pri algoritme C5.0 je, že po rozdelení sa údaje rozdelia na viac ako jeden oddiel. Preto funkcia na výpočet Entropie (S_2) musí zväžiť celkovú entropiu naprieč všetkými oddielmi. Dosahuje to vážením entropie každého rozdelenia pomerom záznamov spadajúcich do daného rozdelenia, čo možno vyjadriť nasledujúcim vzorcom: (Kuhn a kol., 2013)

$$\text{Entropia}(S) = \sum_{i=1}^n w_i \text{Entropia}(P_i) \quad (18)$$

3.6.3 Rozhodovací strom CHAID

Algoritmus CHAID možno charakterizovať ako vhodný metodický nástroj na formu multivariačnej analýzy, ktorý prostredníctvom redukcie dimenzionality údajov umožňuje identifikovať nezávislé premenné, ktoré majú najsilnejšiu interakciu so závislou premennou (Milanovič a Stamenkovič, 2016). Medzi ďalšie výhody algoritmu CHAID zaradili autori Díaz-Pérez a kol. (2016): Chí-kvadrát je neparametrická štatistika, za prediktory možno považovať premenné nominálneho typu a intervalové premenné, za závislé premenné možno

zvoliť spojité premenné. Ak je cieľová premenná Y množinové (kategorické) pole, testuje sa nulová hypotéza nezávislosti X a Y . Na vykonanie testu sa vytvára kontingenčná (početná) tabuľka s použitím tried Y ako stĺpcov a kategórií prediktora X ako riadkov. Očakávané bunkové frekvencie podľa nulovej hypotézy nezávislosti sú odhadnuté. Pozorované bunkové frekvencie a očakávané bunkové frekvencie sa používajú na výpočet chí-kvadrát χ^2 štatistiky a p -hodnota je založená na vypočítanej štatistike. (IBM SPSS Modeler, 2021)

Výpočty neupravených p -hodnôt závisia od typu cieľového poľa. Počas kroku zlúčenia sa kategórie porovnávajú po pároch, to znamená, že jedna (možno zložená) kategória sa porovnáva s inou (možno zloženou) kategóriou. Pri takýchto porovnaníach sa berú do úvahy iba záznamy patriace do jednej z porovnávacích kategórií v aktuálnom uzle. Počas kroku rozdelenia sa pri výpočte p -hodnoty berú do úvahy všetky kategórie, takže všetky záznamy v aktuálnom uzle sa porovnávajú s ostatnými. Testovacia štatistika pre chí-kvadrát χ^2 test nezávislosti je definovaná ako: (Kent State University Libraries, 2017)

$$\chi^2 = \sum_{i=1}^R \sum_{j=1}^C \frac{(o_{ij} - e_{ij})^2}{e_{ij}}, \quad (19)$$

kde o_{ij} vyjadruje pozorovanú početnosť i -tého riadku a j -tého stĺpca kontingenčnej tabuľky, naopak, e_{ij} vyjadruje očakávanú početnosť i -tého riadku a j -tého stĺpca kontingenčnej tabuľky. Vypočítaná hodnota χ^2 sa následne porovná s kritickou hodnotou z tabuľky rozdelenia χ^2 so stupňami voľnosti $df = (R - 1)(C - 1)$ a zvolenou úrovňou hladiny významnosti. V prípade, ak vypočítaná hodnota $\chi^2 >$ kritická hodnota χ^2 , potom zamietame nulovú hypotézu. Rozdiel medzi pozorovanou a očakávanou početnosťou ($o_{ij} - e_{ij}$) možno opísať ako rezíduum, ktoré sa značí ako r_{ij} . Očakávaná hodnota e_{ij} je vypočítaná ako podiel súčinu súm riadkov i a stĺpcov j k celkovému súčtu: (Kent State University Libraries, 2017)

$$e_{ij} = \frac{\sum_{i=1}^R i \cdot \sum_{j=1}^C j}{\sum_{i,j=1}^{R,C} i + j} \quad (20)$$

Pomer pravdepodobnosti chí-kvadrát sa vypočíta na základe očakávaných a pozorovaných frekvencií, ako je opísané vyššie. Pomer pravdepodobnosti chí-kvadrát sa vypočíta ako: (IBM SPSS Modeler, 2021)

$$G^2 = 2 \sum_{j=1}^J \sum_{i=1}^I o_{ij} \ln(o_{ij} / \hat{e}_{ij}), \quad (21)$$

kde p -hodnota je vypočítaná ako $p = \Pr(\chi^2_d > G^2)$.

Pre modely s cieľovou premennou na úrovni stupnice sa *p-hodnota* vypočíta na základe štandardného F-testu ANOVA porovnávajúceho priemer cieľového poľa naprieč kategóriami uvažovaného prediktorového poľa. F-štatistika sa vypočíta ako: (IBM SPSS Modeler, 2021)

$$F = \frac{\sum_{i=1}^I \sum_{n \in D} w_n f_n I(x_n=i) (\bar{y}_i - \bar{y})^2 / (I-1)}{\sum_{i=1}^I \sum_{n \in D} w_n f_n I(x_n=i) (y_n - \bar{y}_i)^2 / (N_f - I)} , \quad (22)$$

kde *p-hodnota* je vyjadrená:

$$p = \Pr (F(I - 1, N_f - I) > F) , \quad (23)$$

$$\bar{y}_i = \frac{\sum_{n \in D} w_n f_n y_n I(x_n=i)}{\sum_{n \in D} w_n f_n I(x_n=i)} , \bar{y} = \frac{\sum_{n \in D} w_n f_n y_n}{\sum_{n \in D} w_n f_n} , N_f = \sum_{n \in D} f_n \quad (24)$$

pričom $F(I - 1, N_f - I)$ je náhodná premenná z *F-rozdelenia* s $(I - 1)$ a $(N_f - I)$ stupňami voľnosti.

Vstupné premenné definované ako forma stupnice (spojité) sú automaticky diskretizované alebo zoskupené do množiny radových kategórií (*angl. binning*). Tento proces sa vykonáva pre každý prediktor na úrovni stupnice v modeli pred aplikáciou algoritmu CHAID. Diskretizácia a jej algoritmus možno opísať nasledovne: (IBM SPSS Modeler, 2021)

1. Hodnoty údajov y_i sú zoradené.
2. Pre každú jedinečnú hodnotu, počnúc najmenšou, je vypočítaná relatívna (vážená) frekvencia hodnôt menších alebo rovných aktuálnej hodnote y_i :

$$cf_i = \sum_{y_k < y_i} w_k , \quad (25)$$

kde w_k predstavuje pre pozorovanie k (v prípade, ak váhy nie sú definované, implicitne je počítané s váhou 1).

3. Určenie hranice pre zoskupenie, do ktorej hodnota patrí, porovnaním relatívnej frekvencie s hraničnými bodmi percentilu zoskupenia 0,10, 0,20, 0,30 atď.

$$bin\ index = \frac{g}{W+1} \times 10 , \quad (26)$$

kde W je celkovou váženou frekvenciou v trénovacej sade dát, $\sum_i w_i$ a

$$g = \begin{cases} cf_{i-1} + \frac{w_i+1}{2}, & w_i \geq 1 \\ cf_{i-1} + \frac{w_i}{2}, & w_i < 1 \end{cases} \quad (27)$$


4 Výsledky práce

Nasledujúca kapitola obsahuje súhrn dosiahnutých výsledkov práce, ktoré sú členené do podkapitol, v ktorých je charakteristika vývoja trhu podnikových dlhopisov, testovanie vzťahov medzi hrubým spreadom a parametrami emisie, analýza hrubého spreadu s využitím metód strojového učenia, a na záver kapitoly je vykonaná analýza a klasifikácia miery preupísanosti podnikových investičných dlhopisov.

4.1 Charakteristika vývoja primárneho trhu podnikových dlhopisov

Na základe dostupných údajov z emisií uskutočnených na agregátnom primárnom trhu dlhopisov bolo možné konštatovať, že podiel podnikových dlhopisov v sledovanom období kolísal v rozmedzí 31.9 až 48.5%. V pandemickom roku 2020 bol pozorovaný najväčší podiel zastúpenia podnikových dlhopisov na úrovni 48.5%. V nasledujúcich rokoch 2021 (42.7%) a 2022 (31.9%) bolo možné pozorovať klesajúci trend zastúpenia podnikových dlhopisov. Naopak, nárast podielu bol v roku 2022 pozorovaný v zastúpení kategórií agentúrnych a finančných dlhopisov. **Graf 2** zachytáva vývoj podielu jednotlivých sektorov na primárnom trhu dlhopisov.

Graf 2 Podiel jednotlivých sektorov emisie na agregátnom primárnom trhu dlhopisov



Zdroj: Vlastné spracovanie.

Trend prezentovaný na **grafe 2** je možné sledovať aj v **tabuľke 4**, ktorej výsledky ukazujú vývoj objemu emitovaného množstva podnikových dlhopisov v jednotlivých

rokoch. V roku 2019 bol zaznamenaný významný nárast v emitovanom objeme podnikových dlhopisov, kedy medziročná zmena v porovnaní s rokom 2018 predstavovala 44,09%. V roku 2020 boli emitované podnikové dlhopisy v celkovom objeme 2,107 miliárd USD, čo predstavovalo medziročnú zmenu o 46.52%. Roky 2021 a 2022 signalizovali klesajúci trend emisie podnikových dlhopisov, keď v roku 2022 bol zaznamenaný najnižší objem (954 miliárd USD) v sledovanom období, čo predstavuje medziročnú zmenu a pokles o -42.46%. Ostatné stĺpce v **tabuľke 4** zobrazujú hodnoty mediánu hrubého spreadu upisovateľa pre jednotlivé úrovne rankingu. V základnej vzorke sa nachádza 15 090 podnikových dlhopisov spadajúcich do kategórie investičné, 133 dlhopisov v kategórii crossover, 4, 423 neinvestičných a 85 dlhopisov je bez udeleného ratingu.

Tabuľka 4 Ročné objemy emisií v mld. Amerických dolárov na primárnom dlhopisovom trhu podnikových dlhopisov a medián hodnoty hrubého spreadu(%) rankingu


rok	objem (mld. USD)	Investičné	Crossover	Neinvestičné	Bez ratingu
2012	1115	3.1	8.3	11	6.9
2013	990	2.6	7.2	9.3	5
2014	1048	2.2	5.5	8.1	6.3
2015	1247	2.6	6.2	9.1	5
2016	1282	2.4	6.8	9.4	4.2
2017	1281	2.1	6	8.6	8.1
2018	998	2.3	4.5	9.3	4.5
2019	1438	2.6	5.6	8.8	7.7
2020	2107	3.5	7.2	9.6	8
2021	1658	2.1	5.6	8.4	5.6
2022	954	2.8	4.6	11	9.9

Zdroj: Vlastné spracovanie.

Prostredná hodnota pri podnikových dlhopisoch, ktoré sú označené ako investičné sa v sledovanom období pohybuje v intervale od 2.1% do 3.5%, pri crossover kategórii od 4.5% do 8.3%, neinvestičné, alebo rizikové dlhopisy sa hýbu od 8.1% do 11% a podnikové dlhopisy bez ohodnotenia od ratingových agentúr majú prostrednú hodnotu v intervale od

4.2% do 9.9%. Na základe výsledkov v **tabuľke 4** bolo možné konštatovať, že medián hrubého spreadu upisovateľov podnikových dlhopisov spadajúcich do kategórie investičných, vykazuje najnižšiu mieru variability v sledovanom období. Naopak, najväčší rozptyl prostrednej hodnoty bol pozorovaný pri podnikových dlhopisoch bez udeleného ratingového ohodnotenia. Ďalším poznatkom z výsledkov v tabuľke 2 je, že prostredná hodnota hrubého spreadu dlhopisov, ktorým nebol udelený rating dosahuje vo všetkých rokoch nižšie hodnoty ako dlhopisy, ktoré spadajú do kategórie neinvestičné. Tabuľku s prehľadom hodnoty mediánu hrubého spreadu upisovateľa pre jednotlivé ratingové ohodnotenia, ktoré udelili agentúra Moodys je možno nájsť v prílohách práce, časť B. V ďalšom kroku sme skúmali agregovaný objem emitovaných prostriedkov na základe regiónu emisie. Využitím Paretovej analýzy prezentovanej na grafe 3, sme chceli zistiť, aký podiel na primárnom trhu majú emitenti z jednotlivých regiónov.

Graf 3 Paretova analýza agregovaného objemu emisií a regiónov v sledovanom období




Zdroj: Vlastné spracovanie.

Paretova analýza na **grafe 3** prezentovala skutočnosť, že primárny trh podnikových dlhopisov bol v sledovanom období z viac ako 80 percent tvorený emisiami v regiónoch Severnej Ameriky a Západnej Európy. Hodnota mediánu hrubého spreadu upisovateľa v závislosti od regiónov emisie je uvedená v prílohách práce, časť B.

V nasledujúcej časti sme sa sústredili na popis primárneho trhu na základe toho aký majú jednotlivý upisovatelia podiel na trhu. Výsledky našich analýz sú základe Paretoho grafu sú uvedené na grafe 4.

Graf 4 Paretova analýza objemu emisií a emitentov podľa odvetvia priemyslu




Zdroj: Vlastné spracovanie.

Celkovo bolo na primárnom trhu s podnikovými dlhopismi v sledovanom období 349 upisovateľov podieľajúcich sa na emisiách. Najväčší objem emitovaných dlhopisov v sledovanom období bol zaznamenaný pri americkej investičnej banke JP Morgan (7.3 miliardy USD), ktorá je nasledovaná ďalšími dvoma americkými bankami Bank of America (6.6 miliardy USD) a CITI Group (6 miliárd USD). Medzi desiatkov najväčších upisovateľov je možné pozorovať štyroch zástupcov z Európy (britské Barclays a HSBC, nemecký Deutsche Bank, francúzsky BNP Paribas). Paretova analýza na **grafe 4** ukázala, že 80% primárneho trhu podnikových dlhopisov v sledovanom období rokov 2012 až 2022 bolo upísaných sedemnástimi investičnými bankami. Pri pohľade na ročné poradie upisovateľov v závislosti od upísaného objemu, je možné konštatovať, že prvá trojica amerických bánk je v každom zo sledovaných rokov na prvých troch priečkach. Vo všeobecnosti je možno považovať prvých pätnásť upisovateľov na trhu podľa ročných objemov za stabilných účastníkov trhu. Stĺpec „Other“ predstavuje súčet 387 ostatných identifikovaných upisovateľov. Prehľad upisovateľov, ktorý sa podieľali na procesoch

emisie na primárnom trhu podnikových dlhopisov a tvorili spolu viac ako 80% trhu v jednotlivých rokoch sledovaného obdobia je uvedený v prílohe, časť B.

Následne sme sa snažili charakterizovať primárny trh s podnikovými dlhopismi na základe odvetvia, v ktorom jednotliví emitenti pôsobia. **Graf 5** prezentuje Paretovu analýzu agregovaného objemu emisií v závislosti od odvetvia priemyslu v ktorom emitent realizoval emisiu dlhopisov.

Graf 5 Paretova analýza objemu emisií a emitentov podľa odvetvia priemyslu



Zdroj: Vlastné spracovanie.

Pri analýze emitovaných objemov podnikových dlhopisov bol najväčší objem v sledovanom období emitovaný v sektore poskytovania zdravotnej starostlivosti a výrobcov farmaceutík. Okrem spomínaného sektoru sa cez hranicu 1000 miliárd USD dostali zástupcovia energetického odvetvia, konkrétne zo sektora energetika a plyn a ropa a plyn. Je treba zdôrazniť, že zobrazených šesť odvetví priemyslu na **grafe 5** tvorilo spolu 80% objemu trhu podnikových dlhopisov, zatiaľ čo zvyšných 20% objemu trhu bol emitovaných v rámci ďalších dvadsiatich dvoch odvetví priemyslu (stĺpec „Ostatné“). Pri prezentovaní výsledkov zastúpenia jednotlivých odvetví je nutné poznamenať, že hoc bol najväčší objem emitovaný v sektore zdravotníctva a farmaceutík, z pohľadu frekvencie výskytu IPO sa umiestnil až za spomínanými odvetviami súvisiacimi s energetikou. Z danej

skutočnosti sme vyvodili záver, že emisie podnikových dlhopisov v zdravotníctve a farmaceutikách sú v priemere emitované vo väčších objemoch.

4.2 Testovanie vzťahov medzi parametrami emisie a hrubým spreadom

Nasledujúca podkapitola sa venuje analýze skúmaných parametrov podnikových dlhopisov na primárnom trhu a skúma rozdiely vo výške hrubého spreadu upisovateľa v závislosti od parametrov, ktoré sme rozdelili na dve časti. Prvá časť sa zameriava na parametre, na ktoré nemá vplyv upisovateľ. Ide o parametre: Mena emisie, Spread benchmark, Región emisie, Rok emisie, Rating: Moodys, Rating: Standard and Poors, Rating: Fitch. V druhej časti sa venujeme parametrom, ktoré majú priamy či nepriamy súvis s upisovateľom. Testovali sme vzťahy medzi hrubým spreadom a reoffer cenou, počtom upisovateľov podieľajúcich sa na emisii, podielom na trhu pre daného upisovateľa, poradovým priemerom umiestnenia jednotlivých upisovateľov v syndikáte, kvartilom umiestnenia syndikátu a preupísanosťou emisie. Na základe výsledkov prezentovaných v metodike práce, v podkapitole 3.6 *hodnotenie platnosti predpokladov*, boli pre štatistickú analýzu parametrov emisie na primárnom trhu dlhopisov zvolené neparametrické testy.

4.2.1 Vybrané základné parametre emisie vo vzťahu k hrubému spreadu


V nasledujúcej podkapitole boli vykonané štatistické testy základných parametrov emisie. Dosiahnuté výsledky umožnili konštatovať, že hrubý spread nemá rovnaké rozdelenie vo všetkých skúmaných parametroch: Mena emisie, Spread benchmark, Región emisie, Rok emisie, Rating: Moodys, Rating: Standard and Poors, Rating: Fitch. Dosiahnuté výsledky nám umožnili zamietnuť všetkých sedem vyslovených hypotéz o rovnakom rozdelení hrubého spreadu. Tabuľka obsahujúca konštatovania o jednotlivých hypotézach, ako aj výsledky testovacej štatistiky Kruskal-Wallis testu s príslušnými hodnotami je k dispozícii v prílohe, časť C.

Následne bol vykonaný post hoc test tzv. neparametrickej verzie ANOVY, test Kruskal Wallis (KW) ktorý porovnáva rozdelenie hrubého spreadu medzi dvojicami jednotlivých kategórií (ďalej sme toto porovnávanie pre potreby práce nazývali ako párové porovnávanie). Príloha, časť C, obsahuje post-hoc analýzu pre párové porovnanie testovaných kategórií. V prípade menových párov boli vybrané tri meny (USD, EUR, GBP), v ktorých bolo v sledovanom období emitovaných viac ako 90% emisií na trhu investičných podnikových dlhopisov. Vo všetkých troch párových porovnaniach bolo možné zamietnuť

nulovú hypotézu a teda rozdelenie hrubého spreadu sa v analyzovaných kategóriách neriadi rovnakým rozdelením.

Pozorovaná hodnota mediánu bola najvyššia v prípade dlhopisov, ktoré boli emitované v britských librách (GBP), konkrétne hodnota hrubého spreadu bola 2.9%, rovnako tak je v tomto prípade sledovaná aj najväčšia variabilita v hodnotách hrubého spreadu. Mediánová hodnota hrubého spreadu emisií v GBP bola o 1% vyššia než mediánová hodnota hrubého spreadu emisií v EUR. V prípade emisií emitovaných v amerických dolároch (USD) bola pozorovaná hodnota mediánu na úrovni 2.5%. Uvedené výsledky sú zobrazené na **grafe 6**.


Graf 6 Box plot analýza hrubého spreadu a meny emisie



Zdroj: Vlastné spracovanie.

Následne bolo vykonané párové porovnanie rozdelenia hrubého spreadu medzi jednotlivými dvojicami regiónov emisie. Na základe post-hoc analýzy bolo možné zamietnuť všetky nulové hypotézy formulované pre H3, s výnimkou dvoch prípadov párového porovnania medzi jednotlivými regiónmi: I. *Zapadaná Európa a Japonsko/Austrália/Nový Zéland* a II. *CEEMEA a Latinskou Amerikou*, kde upravená *p-hodnota* presiahla stanovenú úroveň 0.05, ako sme aj uviedli v prílohe časť C. Grafické znázornenie prostrednej hodnoty mediánu je vo forme box plotov uvedené na **grafe 7**.

Graf 7 Box plot analýza regiónu emisie a hrubého spreadu




Zdroj: Vlastné spracovanie.

Následne bola vykonaná box plot analýza pozorovaného hrubého spreadu upisovateľa v jednotlivých rokoch. Na základe pozorovania hodnoty mediánu hrubého spreadu bolo možno pozorovať sínusoidu opisujúcu hodnotu mediánu hrubého spreadu. Najvyššia pozorovaná hodnota mediánu 3.05%, rovnako aj najvyššia variabilita boli pozorované v roku 2020, kým najnižšia hodnota mediánu skúmanej vzorky bola pozorovaná v rokoch 2017 a 2021 na úrovni 1.95%. Z grafu opisujúceho hodnotu mediánu hrubého spreadu v jednotlivých rokoch nebolo možné jednoznačne určiť trend, avšak na základe pozorovania a komparácie bolo možné tvrdiť, že v rokoch, ktoré na boli trhoch poznačené krízou (2012 – vrchol európskej dlhovej krízy, 2020 – vypuknutie pandémie COVID-19, 2022 – agresia Ruska na Ukrajine), mal hrubý spread tendenciu vykázať vyššie hodnoty ako v predchádzajúcom období. Graf je možno nájsť v prílohe, časť C.

Pri porovnávaní jednotlivých ratingových ohodnotení sme pozorovali rastúcu prostrednú mediánovú hodnotu hrubého spreadu upisovateľa s rastúcim ratingovým ohodnotením a teda rastúcim rizikom kredibility emitenta. Rovnako tak bolo možné sledovať aj rastúcu variabilitu hrubého spreadu spolu s rastúcim rizikom. Po úroveň ratingového ohodnotenia od Moodys A3, čo je pri lineárnej transformácii rizikový stupeň 7, bolo možné pozorovať, že hodnota hrubého spreadu nepresahuje úroveň 2%. Od známky Baa1 (rizikový stupeň 8) už však bolo možné pozorovať významný nárast mediánu aj variability. Grafické znázornenie je prezentované na **grafe 8**.

Graf 8 Box plot analýza ratingového ohodnotenia Moodys a hrubého spreadu



Zdroj: Vlastné spracovanie

Hoci sme v rámci metodológie zdôraznili, že sa budeme zaoberať investičnými podnikovými dlhopismi, dôvodom prečo sa na **grafe 8** vyskytujú podnikové dlhopisy s udeleným ratingom vyšším ako stupeň rizika = 10, (čo značí, že dlhopis do tejto kategórie nespadá), je ten, že iná kreditná ratingová agentúra vo vzorke (Standard and Poors, Fitch) danému dlhopisu udelila rating spadajúci do kategórie investičných dlhopisov a teda ≤ 10 . Podľa pravidiel pri viacnásobnom ohodnotení viacerými ratingovými agentúrami sa berie do úvahy najlepší rating.

Následne bol vykonaný test štatistickej závislosti, kde sme testovali koreláciu medzi hrubým spreadom upisovateľa a ratingom, ktorý bol danej emisii udelený jednou z troch ratingových agentúr. Hladina významnosti α bola stanovená na úroveň 0.05. Na základe výsledkov *Spearmanovho* korelačného koeficientu Rho bolo možné konštatovať, že pri všetkých troch ratingových agentúrach sú korelácie významné na úrovni 0.01 a pozitívne. Najsilnejšiu koreláciu sme sledovali vo vzťahu k ratingu od agentúry Standard and Poors. Výsledky korelačnej analýzy naznačujú existenciu stredne silných závislostí medzi ratingom poskytnutým všetkými testovanými ratingovými agentúrami a hrubým spreadom. Najväčšia závislosť bola pozorovaná v prípade ratingu od S&P najnižšia v prípade ratingu od agentúry Fitch. **Tabuľka 5** prezentuje dosiahnuté výsledky.

Tabuľka 5 Spearmanov korelačný koeficient – vzťah Hrubý spread a Rating

Hrubý spread upisovateľa		Rating: Moodys	Rating: Stand. and Poors	Rating: Fitch
	Spearman Rho	0.535**	0.552**	0.502**
	p-hodnota	0.000	0.000	0.000
	N	9824	10148	4807

Zdroj: Vlastné spracovanie

Následne sme vykonali testovanie korelácie medzi hrubým spreadom a parametrami objem emisie a splatnosť dlhopisu. Podobne ako v predchádzajúcej korelácii, aj v tomto prípade boli korelácie medzi závislou a nezávislými premennými štatisticky významné na úrovni $\alpha = 0.01$, avšak výsledné hodnoty *Spearmanovho* korelačného koeficientu boli blízke nule. Pri objeme emisie dosiahol korelačný koeficient hodnotu -0.096, splatnosť dlhopisu bola zaznamenaná na úrovni 0.199. Výsledky vo forme korelačnej tabuľky sú uvedené v prílohe, časť C.


4.2.2 Vybrané parametre upisovateľa emisie vo vzťahu k hrubému spreadu

V druhej časti analýzy vybraných parametrov emisie bol dôraz kladený na testovanie vplyvu reputácie upisovateľa, resp. syndikátu upisovateľov na skúmanú premennú hrubý spread upisovateľa.

Ako prvý sme testovali vzťah medzi hrubým spreadom emisie a reoffer cenou a teda cenou, za ktorú bola daná emisia upisovateľom ponúknutá investorom. V tomto prípade neparametrický test Kruskal-Wallis umožnil zamietnuť nulovú hypotézu pre H8, ktorá znela, že rozdelenie hrubého spreadu je rovnaké vo **všetkých** kategóriách reoffer ceny. Následne bola vykonaná post hoc analýza, v rámci ktorej boli porovnávané jednotlivé dvojice situácií, ktoré pri reoffer cene nastali. Nakoľko reoffer cena je vyjadrená percentuálne, ako podiel z celkovej hodnoty emisie, vytvorili sme umelú premennú, kde hodnota -1 značila, keď bola reoffer cena nižšia, ako hodnota emisie (reoffer < 100%). Hodnota 0 predstavovala situáciu, keď bola reoffer cena rovnaká ako hodnota emisie (reoffer = 100%). Hodnota 1, bola situáciou, v ktorej upisovateľ ponúkol emisiu dlhopisu investorom za vyššiu cenu, ako bola celková hodnota emisie (reoffer > 100%). Vo všetkých troch párových porovnaniach pre hypotézy H8.1-H8.3 bolo možné zamietnuť nulovú hypotézu, nakoľko rozdelenie hrubého

spreadu nebolo rovnaké naprieč jednotlivými porovnávanými kategóriami. Podobne korelačná analýza nepotvrdila silnú závislosť medzi reofferom a spreadom. Výsledky post hoc analýzy je možné nájsť v prílohe, časť C. Výsledky zobrazené na **grafe 9** prezentovali, že najvyššia prostredná hodnota hrubého spreadu (2.65%) bola pozorovaná v prípadoch, kedy boli dlhopisy ponúknuté investorom od upisovateľa za rovnakú cenu (objem), ako ich upisovateľ nakúpil od emitenta. Naopak, najnižšia hodnota mediánu hrubého spreadu (1.06%) bola pozorovaná, ak upisovateľ dokázal investorom emisiu ponúknuť za vyššiu cenu, za akú emisiu zakúpil od emitenta

Graf 9 Box plot analýza hodnoty reoffer ceny a hrubého spreadu




Zdroj: Vlastné spracovanie.

V ďalšom kroku sme sa sústredili na porovnanie syndikátov, ktoré mali v rámci daného roka aspoň jedného upisovateľa v TOP5, TOP10, TOP15 a TOP20. Ako sme uviedli v metodológii, TOP5 predstavuje skupinu syndikátov, ktorí mali najlepšie umiestneného upisovateľa za daný rok na 1 – 5 mieste. Ďalšie kategórie sú: TOP10 (najlepší upisovateľ na 6 – 10), TOP15 (najlepší upisovateľ na 11 – 15 mieste) a TOP20 (najlepší upisovateľ na 16 – 20 mieste). Využitie Kruskal-Wallis testu na štatistické testovanie hrubého spreadu medzi syndikátmi patriacimi do týchto kategórií preukázalo štatisticky významné rozdiely vo výškach hrubého spreadu. Následné post-hoc analýzy pozostávali z párového porovnávania jednotlivých kategórií. Výsledky štatistického testovania nepreukázali existenciu štatisticky významných rozdielov (na úrovni významnosti $\alpha = 0.05$) vo výške hrubého spreadu medzi kategóriami TOP10, TOP15 a TOP20. Výsledky párových testov sú uvedené prílohe, časť

C a na **grafe 10**. Kde bolo možné pozorovať, že prostredná hodnota hrubého spreadu pre emisie, ktorých najlepšie umiestnený upisovatelia boli od šiesteho do dvadsiateho miesta (TOP10, TOP15 a TOP20) mala mierne klesajúcu tendenciu v intervale 2.15% až 2.03%. Významné rozdiely bolo možné pozorovať pri emisiách s upisovateľmi umiestnenými na 1 – 5 mieste alebo neumiestnenými upisovateľmi (TOP5 a mimo TOP20). Z dvadsiatky najlepších bola najvyššia prostredná hodnota (2.36%) zaznamenaná pri upisovateľoch upisujúcich objemy medzi prvou päťkou. Absolútne najvyššia prostredná hodnota hrubého spreadu bola pozorovaná pri upisovateľoch mimo TOP 20 (2.55%), rovnako aj najväčšia variabilita hrubého spreadu, najvyššie zaznamenané maximum a minimum.

Graf 10 Box plot analýza hrubého spreadu a postavenia upisovateľa (ročný objem)




Zdroj: Vlastné spracovanie.

Pri testovaní korelačných vzťahov medzi hrubým spreadom upisovateľa a parametrami emisie súvisiacimi s upisovateľom sme sa zamerali aj na počet upisovateľov emisie, trhovú podiel syndikátu upisovateľov, dopyt po IPO, početnosti vzťahov medzi emitentom a upisovateľom a preupísanosti. Vo všetkých prípadoch boli pozorované štatisticky významné korelácie na hladine významnosti $\alpha = 0.01$, s výnimkou vzťahu, hrubý spread upisovateľa a trhovú podiel syndikátu, kde boli dosiahnuté štatisticky významné výsledky na hladine významnosti $\alpha = 0.05$. Podobne ako v predchádzajúcom príklade nebolo možné konštatovať existenciu jednoznačných vzťahov, najsilnejší korelačný koeficient bol pozorovaný pri vzťahu hrubý spread a dopyt a to na hodnote 0.168. Výsledky možno nájsť v tabuľkách uvedených v prílohe, časť C.

V analýze vybraných parametrov upisovateľa vo vzťahu k hrubému spreadu bola vykonaná aj post hoc analýza hrubého spreadu a medziročnej zmeny postavenia syndikátu upisovateľov vo vzťahu k upísanému objemu. V tomto prípade sme sledovali, či existujú štatisticky významné rozdiely, ak syndikát mení svoje postavenie na trhu. Zmenu postavenia sme klasifikovali do troch skupín, kde zhoršenie postavenia syndikátu reprezentovalo prepad v rebríčku syndikátov podľa ročného upísaného objemu investičných podnikových dlhopisov. Zlepšenie postavenia značilo situáciu, že daný syndikát vylepšil svoje postavenie v porovnaní s ostatnými syndikátmi a umiestnil sa vyššie. V prípade, ak sa umiestnil rovnako, išlo o kategóriu, ktorá značila rovnaké postavenie. Vo všetkých hypotézach H20.1 – H20.3 sme mohli zamietnuť nulovú hypotézu o rovnakom rozdelení hrubého spreadu v prípade zmeny postavenia. Výsledky preukázali, že v prípade desiatky najlepších syndikátov sa hrubý spread pohyboval na najnižšej hodnote v prípadoch, ak sa ich medziročné postavenie nemenilo. Pri syndikátoch postavených v prvej dvadsiatke sme mohli takisto konštatovať klesajúci trend prostrednej hodnoty hrubého spreadu, ako to bolo pri analýze hrubého spreadu a postavenia upisovateľa uvedeného vyššie. Pri upisovateľoch z prvej pätnástky bolo možné sledovať, že akákoľvek zmena postavenia viedla k nárastu hrubého spreadu. Grafické znázornenie sa nachádza na **grafe 11**.


Graf 11 Box plot analýza hrubého spreadu a medziročnej zmeny postavenia syndikátu



Zdroj: Vlastné spracovanie.

Na záver tejto podkapitoly sme vykonali box plot analýzu znázorňujúcu prostrednú hodnotu hrubého spreadu upisovateľa a preupísanosti emisie. V prípadoch ak emisia bola preupísaná, je pri upisovateľoch postavených v prvej pätnástke pozorovaná vyššia hodnota hrubého spreadu v porovnaní so situáciami, keď emisia preupísaná nebola. Výnimkou bola kategória, ak boli pozorovaní upisovatelia umiestnení na pozíciách 16 – 20 (TOP 20). V prípade, ak emisia bola preupísaná, kategória upisovateľov TOP20 ukázala nižšiu prostrednú hodnotu hrubého spreadu (2.1%) v porovnaní s opačným javom (2.36%), ako je znázornené na **grafe 12**. Pri preupísaných emisiách bolo taktiež možné pozorovať vo všeobecnosti vyššiu variabilitu a medzikvartilové rozpätie.

Graf 12 Box plot analýza hrubého spreadu a preupísanosti emisie



Zdroj: Vlastné spracovanie.

4.3 Analýza vzťahov hrubého spreadu s využitím metód strojového učenia

V nasledujúcej podkapitole bolo vykonané testovanie vzťahov medzi hrubým spreadom a jednotlivými parametrami dlhopisov, na rozdiel od predchádzajúcej podkapitoly sme však v tomto prípade využili techniky strojového učenia. Na záver podkapitoly je

vytvorený klasifikačný model pre definíciu pravidiel určenia výšky hrubého spreadu a jeho determinantov. Cieľom tejto časti analytickej práce bolo kvantifikovať vplyv a významnosť skúmaných parametrov a vytvoriť model s čo najlepšimi výkonnostnými metrikami pri predikcii, resp. klasifikácii.

4.3.1 Testovanie vzťahu medzi hrubým spreadom a základnými parametrami emisie

Prvým krokom bolo vytvoriť model, ktorý bude obsahovať iba základné parametre dlhopisov, ako bolo špecifikované v metodologickej časti práce. Pre predikciu hrubého spreadu a kvantifikáciu vplyvu jednotlivých základných parametrov bol primárne použitý regresný strom XGBoost, ktorého dosiahnuté výkonnostné metriky sme porovnávali s dvoma príbuznými technikami strojového učenia: *Random Forest* a umelými neurónovými sieťami (ANN). Pre komparáciu bola použitá aj Huberova regresia, ako bolo uvedené v metodologickej časti práce. Prvá sledovaná metrika na vyhodnocovanie výkonnosti modelu bola MSE (*Mean Squared Error*), merala priemer štvorcov chýb medzi predikovanými hodnotami a skutočnými – pozorovanými hodnotami. Ďalšou metrikou bola RMSE (*Root Mean Squared Error*), ktorá je strednou kvadratickou chybou MSE a vyjadruje priemernú absolútnu chybu medzi predikovanými a skutočnými hodnotami. Tretia metrika bola R^2 skóre (*Koeficient determinácie*), ktorá vyjadruje percentuálne vysvetlenie rozptylu závislej premennej modelom.

Pri predikcii hrubého spreadu na báze základných parametrov dosiahol XGBoost MSE = 0.5207, čo indikovalo najpresnejší model v závislosti od danej metriky. V prípade RMSE boli najlepšie metriky zaznamenané taktiež pri použití modelu využívajúceho regresor XGBoost a bolo možné konštatovať, že priemerná chyba v predikcii hrubého spreadu bola 0.72%. Vyššie hodnoty R^2 skóre pri použití XGBoost indikovali, že model dokázal vysvetliť väčšiu časť rozptylu závislej premennej. Z týchto metrík je zrejmé, že XGBoost dosahuje najlepšie výsledky v predikcii hrubého spreadu upisovateľa, nasledovaný Random Forest, ANN a regresiou. Tieto výsledky naznačujú, že XGBoost bol najpresnejším modelom a v kontexte základných parametrov mal najlepšiu schopnosť predikovať závislú premennú. Dosiahnuté metriky sú prezentované v **Tabuľke 6**. Následne sme analyzovali priemernú absolútnu hodnotu jednotlivých základných parametrov v modeli XGBoost. Najvyššia priemerná absolútna hodnota vplyvu na hrubý spread bola zaznamenaná pri


ratingových ohodnoteniach emitentov od Moodys a Standard and Poors, ako je prezentované na grafe 13.

Tabuľka 6 Hodnotenie predikčnej schopnosti modelu na základe základných parametrov

	XGBoost	Random Forest	ANN	Regresia
MSE	0.5207	0.7562	0.6877	0.8621
RMSE	0.7216	0.8696	0.8293	0.9285
R^2 skóre	0.3291	0.2999	0.2644	0.1327

Zdroj: Vlastné spracovanie.

Graf 13 Priemerná absolútna hodnota základných parametrov: XGBoost




Zdroj: Vlastné spracovanie.

V porovnaní s ratingovým ohodnotením agentúry Fitch, tak išlo o viac ako 5-krát vyšší priemerný vplyv ratingového ohodnotenia od Standard and Poors a Moodys. Podľa výsledkov bolo možné konštatovať, že spolu s ratingovým ohodnotením má významný vplyv na hrubý spread aj splatnosť dlhopisu (*maturity_years_rounded*), ktorá bola vyhodnotená ako tretí najvplyvnejší parameter. Pri pohľade na regióny emisie a ich priemernú absolútnu hodnotu vplyvu na hrubý spread upisovateľa bolo možné konštatovať, že oba z najviac zastúpených regiónov Severná Amerika a Západná Európa sa ukázali ako signifikantné pre model. Najväčší priemerný absolútny vplyv na hrubý spread však z regionálneho hľadiska bol pozorovaný pri emisiách z Ázie. Významnú priemernú absolútnu hodnotu základných parametrov sme pri modeli zaznamenali aj pri indikátoroch kondície trhu. Najvplyvnejším zo zmienených indikátorov sa v tomto prípade javil európsky index podnikových dlhopisov EAGG.PA, konkrétne jeho oneskorená hodnota o osem mesiacov (*EAGG.PA_lag_8mon*). Ako významné sa ukázali aj hodnoty VIX či VCIT, čo možno priamo neovplyvnilo dohodnutú zmluvnú výšku hrubého spreadu, avšak dané indexy ovplyvňujú náladu investorov na trhu, čo má za následok ovplyvnenie dopytu s ktorým upisovateľia pri emisii môžu očakávať.

Následne sme vykonali analýzu pomocou grafu SHAP (Shapley Additive Explanations). Na rozdiel od **grafu 13** nie sú hodnoty jednotlivých parametrov vyjadrené v absolútnej hodnote, čo umožnilo analyzovať individualizovanú mieru dôležitosti funkcie parametru v každom pozorovaní vo vzorke. Pri pohľade na individualizovanú mieru dôležitosti funkcie skúmaných parametrov na **grafe 14**, je možné konštatovať, že pri všetkých z troch ratingových agentúr je trend vplyvu zrejмый. S rastúcou hodnotou udeleného ratingu (červená farba), rastie aj výška hrubého spreadu a čím nabera rating nižšiu hodnotu (nižšie riziko – modrá farba), vplyv na hrubý spread je negatívny. Parameter *EAGG.PA_lag_8mon* rovnako signalizoval vzťah medzi indexom zobrazujúcim kondíciu európskych podnikových investičných dlhopisov. Pokiaľ bol daný parameter pred ôsmimi mesiacmi od emisie pozorovaný vo vyšších hodnotách (trh vykazoval rast), tak to malo pozitívny vplyv aj na hrubý spread upisovateľa. Rozdielny trend je pozorovaný pri amerických investičných podnikových dlhopisoch, kde je parametrom index *VCIT_lag_8mo*, ktorého hodnota mala výrazný vplyv bez ohľadu na to, či sa index nachádzal v období rastu alebo poklesu pred ôsmimi mesiacmi od emisie.

Graf 14 SHAP hodnoty pre základné parametre dlhopisov



Zdroj: Vlastné spracovanie.

4.3.2 Testovanie vzťahu medzi hrubým spreadom a parametrov súvisiacich s upisovateľom

Podobne ako pri základných parametroch, aj pri parametroch súvisiacich s upisovateľom emisie bola vykonaná komparácia výkonnostných metrík modelov

zameraných na presnosť vykonaných predikcií. V prípade testovania vzťahu medzi hrubým spreadom a parametrov súvisiacich s upisovateľom boli najlepšie dosiahnuté s využitím regresného stromu XGBoost, ako uvádzajú výsledky uvedené v **Tabuľke 7**.

Tabuľka 7 Hodnotenie predikčnej schopnosti modelu na základe parametrov súvisiacich s upisovateľom emisie


	XGBoost	Random Forest	ANN	Regresia
MSE	1.2105	1.3061	1.3277	6.8448
RMSE	1.1002	1.1428	1.1523	2.6163
R^2 skóre	0.1088	0.0384	0.0220	-4.0395

Zdroj: Vlastné spracovanie.

V porovnaní so základnými parametrami emisie bola presnosť predikcie na parametroch súvisiacich s upisovateľom výrazne slabšia. Priemerná chyba v predikcii hrubého spreadu pomocou XGBoost na základe parametrov súvisiacich s upisovateľom dosiahla 1.10%, kým koeficient determinácie dosiahol hodnotu 0.1088. V prípade regresie s využitím špecifikácie od Hubera bol zaznamenaný negatívny koeficient determinácie, čo viedlo ku konštatovaniu, že model bol veľmi neúspešný a jeho výsledky boli horšie ako priemer hodnôt závislej premennej. Negatívne R^2 skóre naznačilo, že model nedokázal správne vysvetliť ani reprodukovať závislú premennú a jeho predikcie boli veľmi nepresné.

Podobne ako pri základných parametroch, aj pri parametroch súvisiacich s upisovateľom sme analyzovali priemerné absolútne hodnoty jednotlivých parametrov a ich vplyv na predikciu hrubého spreadu. Dva najvplyvnejšie pozorované parametre: počet vzťahov medzi emitentom a upisovateľom (*rel_issuer_UW*) a priemerný počet emisií za kalendárny rok (*relation_year*) vyjadrujú opakovaný vzťah, resp. periodicitu emisií. V porovnaní s najvplyvnejšími základnými parametrami (*s&p_rating* a *moodys_rating*) však dosiahli nižšie priemerné absolútne hodnoty, na úrovni 0.1, resp. 0.092. Výsledky priemerných absolútnych hodnôt v rámci parametrov súvisiacich s upisovateľom naznačili, že celkový vplyv a významnosť skúmaných parametrov je výraznejšie rozdzielovaná a nie je tak sústredená k jednotlivým parametrom. Pre porovnanie, pri základných parametroch tri najvýznamnejšie premenné dosiahli významnosť na predikciu v súčte 0.75, zatiaľ čo pri parametroch súvisiacich s upisovateľom bola dosiahnutá hodnota 0.26.

Graf 15 Priemerná absolútna hodnota parametrov súvisiacich s upisovateľom: XGBoost




Zdroj: Vlastné spracovanie.

Pri skúmaní individualizovanej miery jednotlivých parametrov vo vzťahu hrubý spread a parametre súvisiace s upisovateľom, bol vo výsledkoch najrelevantnejší parameter *relation_year*, ktorý súvisí s priemerným ročným výskytom emitenta na trhu investičných podnikových dlhopisov. **Podľa grafu 16** bolo možné konštatovať, že opakovaná emisia dlhopisov počas jedného kalendárneho roka má v modeli negatívny vplyv na hrubý spread upisovateľa. Opísanú skutočnosť je možné potvrdiť aj podľa parametra *issuer_first_appearance*, ktorý opisuje, či sa jedná o prvú emisiu daného emitenta

v skúmanej vzorke (vyjadrené červenou farbou), alebo ide o emisiu emitenta, ktorý už na trhu emitoval (modrá farba).

Graf 16 SHAP hodnoty pre parametre dlhopisov súvisiacich s upisovateľom



Zdroj: Vlastné spracovanie.

Analýza pomocou grafu SHAP ukázala, že pri parametri *reoffer* bolo možné sledovať, že nízke hodnoty *reoffer* ceny viedli k nárastu hrubého spreadu, zatiaľ čo vysoké hodnoty *reoffer* ceny majú zmiešaný a nejednoznačný vplyv. Parametre opisujúce upisovateľov, resp. syndikáty neukázali konzistentné vplyvy. Parameter, ktorý uvádza

objem upísaný daným syndikátom (*SHARE_syndicate_lagged*), ukázal, že s jeho rastúcou hodnotou, je možné uvažovať o jeho negatívnom vplyve na výšku predikovaného hrubého spreadu (hrubý spread bude nižší). Podobný efekt je možné pozorovať aj pri parametri ukazujúcom priemerné postavenie syndikátu (*RANK_syndicate_lagged*), kde s rastúcou hodnotou ranku (menší objem upísaný v predchádzajúcom roku) rastie aj efekt na predikovanú výšku hrubého spreadu). Naopak, parameter vyjadrujúci poradový priemer kvartilov syndikátu (*QUARTILE_syndicate_lagged*) znázornil, že s rastúcim kvartilom je predikovaný negatívny efekt na hrubý spread (hrubý spread klesá). V tomto prípade kategorická premenná vykázala odlišný vplyv ako *SHARE_syndicate_lagged*, zatiaľ čo *SHARE_syndicate* je agregovaná hodnota za emitované ročné objemy spolu, *QUARTILE_syndicate* je priemerná hodnota postavenia všetkých upisovateľov syndikátu.

Následne sme sa zamerali na izolovaný vplyv (zmena ostatných parametrov nie je braná do úvahy) parametra *relation_year*, ktorý súvisí s výskytom emitenta na trhu v priebehu roka. V prípade, ak sa emitent vyskytol na trhu prvýkrát – na hrubý spread to nemalo žiadny zásadný vplyv. V prípade, ak sa vyskytol v priebehu roka druhý, tretí, alebo viacerí krát, viedlo to k zníženiu hrubého spreadu. V prípade, ak išlo o druhý výskyt emitenta, priemerná hodnota poklesu hrubého spreadu je -0.04 percenta z hodnoty emisie. Ak sa emitent na trhu vyskytol tretí alebo štvrtýkrát (súradnica 3 na horizontálnej osi), viedlo to k zníženiu hrubého spreadu o ďalších -0.15 percenta, čo kumulatívne predstavuje -0.19 percenta v priemere. V prípade, ak emitent na trhu v priebehu roka absolvoval päť a viac emisií (súradnica 4 na horizontálnej osi), priemerné ďalšie zníženie spreadu bolo -0.2 percenta (-0.39 percenta kumulatívne). Izolovaný vplyv parametra na výšku hrubého spreadu emisie bol skúmaný aj pri parametroch: počet upisovateľov emisie, rank syndikátu upisovateľov v roku emisie a rok pred emisiou. Pri počte upisovateľov bol pozorovaný nárast výšky hrubého spreadu, ak boli v emisii viac ako traja upisovatelia. Do troch upisovateľov bol vplyv na výšku predikovaného hrubého záporný. Pri parametri *RANK_syndicate* sme mohli konštatovať, že výsledky sú konzistentné so zisteniami v *podkapitole 4.2.2* a v prvej dvadsiatke upisovateľov je klesajúci trend hrubého spreadu s následným nárastom pri upisovateľoch umiestnených mimo TOP 20. Graf k izolovanému vplyvu daných parametrov je možné nájsť v prílohe – časť D.

4.3.3 Testovanie vzťahu hrubého spreadu a kombinácie základných parametrov a parametrov súvisiacich s upisovateľom dlhopisu

V nasledujúcej časti boli testované vzťahy medzi hrubým spreadom a kombináciou všetkých parametrov, ktorých vplyv na hrubý spread bol testovaný v predchádzajúcich podkapitolách. Aj v tomto prípade boli dosiahnuté najlepšie metriky s využitím regresného stromu XGBoost. Pri hodnotení výsledných hodnôt koeficientu determinácie bolo možné konštatovať, že model, ktorý obsahuje kombináciu základných parametrov a parametrov súvisiacich s upisovateľom dokázal vysvetliť viac ako 50% rozptylu hrubého spreadu na základe testovaných prediktorov. V porovnaní s ostatnými metódami išlo o jediný prípad, keď bola prekročená hranica koeficientu determinácie $R^2 > 0.5$. Okrem koeficientu determinácie dosiahol XGBoost najlepšie metriky aj v priemernej absolútnej chybe medzi predikovanými a skutočnými hodnotami, keď $RMSE = 0.9231$. V tomto prípade bolo potrebné poznamenať, že ak porovnáваме dosiahnuté metriky s výsledkami pre model, ktorý predikuje len na základe základných parametrov, dosiahli sme lepší koeficient determinácie, avšak priemerná absolútna chyba predikcie je v modeli využívajúcom iba základné parametre nižšia. V tomto prípade je priemerná absolútna chyba pri kombinovaných parametroch vyššia o 0.2%, ako je uvedené v **tabuľke 8**, ktorá obsahuje výsledky nameraných metrík na hodnotenie predikčnej schopnosti testovaných modelov.

Tabuľka 8 Hodnotenie predikčnej schopnosti modelu: kombinované parametre

	XGBoost	Random Forest	ANN	Regresia
MSE	0.8521	0.9384	1.0446	1.2316
RMSE	0.9231	0.9687	1.0221	1.1098
R^2 skóre	0.5368	0.4919	0.4321	0.3304

Zdroj: Vlastné spracovanie.

Podobne ako v predchádzajúcich podkapitolách, aj v tomto prípade boli pozorované priemerné absolútne hodnoty parametrov a ich vplyv na hrubý spread a rovnako tak aj ich individualizované miery. V tomto prípade sme mohli konštatovať, že parametre s najväčším vplyvom sa signifikantne nelíšia od parametrov, ktoré mali významný vplyv, ak boli testované len základné parametre a teda, v tomto prípade nebolo možné pozorovať vplyv parametrov, ktoré majú súvis s upisovateľom. Pri komparácii s predchádzajúcimi

nameranými hodnotami parametrov a ich významnosti bolo v tomto prípade pozorované, že významnosť ratingových ohodnotení od Moodys aj Standard and Poors vzrástla. Grafy obsahujúce priemernú absolútnu hodnotu parametrov, ako aj individualizované hodnoty pre parametre vo forme SHAP grafu je možno nájsť v prílohe, časť E.

4.3.4 Testovanie vzťahu hrubého spreadu a parametrov emisie pri definovaných externých faktoroch

V nasledujúcej časti sme testovali vzťah hrubého spreadu a parametrov emisie a to za predpokladu, že vychádzame zo vzorky údajov, kde sú definované externé faktory, na ktoré podnik nemá dosah a nevie ich zmeniť. Jednalo sa o externé faktory, ktoré opisujú: **región emisie**, v ktorom podnik emituje; **odvetvie priemyslu**. Cieľom definovania týchto externých faktorov bolo zlepšenie predikčných schopností modelu.

Celkovo bolo identifikovaných 330 vzoriek, ktoré boli definované kombináciou 6 regiónov a 55 odvetví priemyslu, pričom pre každú vzorku bol vytvorený vlastný XGBoost model. Vo vytvorených 330 modeloch bolo v súčte identifikovaných 6184 významných parametrov. Na všetkých vytvorených vzorkách bola vykonaná analýza početnosti výskytu jednotlivých parametrov. Najčastejšie sa vyskytujúcim parametrami boli: objem emisie (*vol_usd*) v 52.73% prípadov; ordinálna premenná vyjadrujúca, či ide o prvú skúsenosť emitenta na primárnom dlhopisovom trhu, alebo sa na trh opakovane vracia (*issuer_appear*) v 44.24%; splatnosť dlhopisu (*maturity_years_rounded*) 40.61%; parameter vyjadrujúci počet vzťahov medzi emitentom a syndikátom upisovateľov na trhu (*rel_issuer_uw*) 36.36%; parameter vyjadrujúci poradie syndikátu upisovateľov v závislosti od upísaného objemu v danom roku (*RANK_syndicate*) 35.76%. Vo významnej miere bolo možné sledovať aj výskyt miery preupísanosti emisie, konkrétne v 66 prípadoch (20%), čo neskôr viedlo k analýze preupísaných emisií v *podkapitole 4.4*. Z pohľadu konkrétnych upisovateľov sa najčastejšie medzi vyznanými parametrami objavovali upisovatelia *BANK_OF_AMERICA* (54 krát), *CITIGROUP* (53 krát), *BARCLAYS* (51 krát) a *BNP_PARIBAS* (50 krát). Prehľad najčastejšie sa vyskytujúcich parametrov ako aj ich percentuálne zastúpenie je možné nájsť v prílohe, časť E.

Pri hodnotení predikčných schopností modelu XGBoost, boli použité rovnaké metriky, ako v prípade predchádzajúcich modelov. Na základe dosiahnutých výsledkov bolo možné potvrdiť, že špecifikácia vzoriek na základe zvolených externých faktorov pomohla výrazným spôsobom zlepšiť predikčnú schopnosť modelu. Bolo možné identifikovať

jedenásť vzoriek, kde bol dosiahnutý $R^2 \geq 0.75$. Pre prehľadnosť boli v **Tabuľke 9** uvedené iba modely, ktorých koeficient determinácie presiahol uvedenú hranicu. Ako je možné sledovať na dosiahnutých metrikách, presnosť predikcií modelov za predpokladu definovaných externých faktorov dosahuje signifikantnejšie lepšie výsledky, ako v predchádzajúcich modeloch.

Tabuľka 9 Hodnotenie predikčnej schopnosti modelu: kombinované parametre a definované externé faktory

Vzorka	n	MSE	RMSE	R^2
Ázia_Železnice	8	0.0206	0.1434	0.9295
Sev.Amerika_Širokopásmové pripojenie	33	0.1319	0.3632	0.9148
Sev.Amerika_Elektronika	212	0.3347	0.5785	0.8501
Sev.Amerika_Letecký a lodný priemysel	21	0.3709	0.6090	0.8180
Ázia_Telekomunikácie	33	0.3999	0.6324	0.7914
Ázia_Chemický priemysel	46	0.2607	0.5105	0.7898
Ázia_Materiály vo výrobe	15	0.3898	0.6243	0.7885
Sev.Amerika_Priemyselná technika	239	0.2462	0.4962	0.7856
CEEMEA_Chemický priemysel	10	0.0226	0.1505	0.7856
Sev.Amerika_Zdravotníctvo a Farmácia	518	0.2904	0.5389	0.7786
Sev.Amerika_Obrana	49	0.4718	0.6869	0.7624

Zdroj: Vlastné spracovanie.

Pri analýze jednotlivých vzoriek s koeficientom determinácie $R^2 \geq 0.75$, ktoré sú uvedené v Tabuľke, príloha časť E, bolo pozorované, že výskyt, vplyv a významnosť jednotlivých parametrov v modeloch bola rôznorodá v závislosti od vzorky. Pri jedenástich analyzovaných vzorkách bolo ratingové ohodnotenie pozorované ako najvýznamnejšie v šiestich prípadoch – trikrát rating udelený od Standard and Poors, dvakrát od Moodys a jedenkrát od agentúry Fitch. V prípade vzorky *Sev.Amerika_letecký a lodný priemysel* bol ako najvplyvnejší parameter na predikciu výšky hrubého spreadu vyhodnotená veľkosť emisie, čo bol v porovnaní s výsledkami dosiahnutými v podkapitole 4.3.1 rozdiel, nakoľko

v predchádzajúcich modeloch sa objem emisie medzi významnými parametrami nevyskytoval.

V prípade vzoriek z regiónu *Sev.Amerika*, v odvetviach *Širokopásmové pripojenie* a *obrana* a vzoriek z regiónu *Ázia* v odvetviach *Chemický priemysel* a *Materiály vo výrobe* boli najvplyvnejšími parametrami parametre súvisiace s upisovateľom. V troch zo štyroch zmienенých vzorkách sa jednalo o parametre vyjadrujúce postavenie syndikátu ako je *RANK* a *QUARTILE*. V jednom prípade bolo ako najvplyvnejší parameter vyhodnotený konkrétny upisovateľ. Pri analýze desiatich najvplyvnejších parametroch na predikciu výšky hrubého spreadu bol pozorovaný konkrétny upisovateľ alebo syndikát upisovateľov dvadsaťpäťkrát, čo predstavovalo 23.81% z pozorovaných parametrov.

Ako bolo konštatované skôr, najčastejšie vyskytujúcim sa parametrom pri predikcii hrubého spreadu bol objem emisie. Z výsledkov dosiahnutých na modeloch s $R^2 \geq 0.75$ bolo možné sledovať, že objem emisie sa medzi troma najvplyvnejšími parametrami vyskytol iba jedenkrát a to konkrétne vo vzorke, kde je predikovaný hrubý spread pre Letecký a lodný priemysel v regióne Severnej Ameriky. Najčastejšie sa vyskytujúcim parametrom bol v tomto prípade udelený rating, celkovo osemkrát, z toho šesťkrát ako najvplyvnejší parameter a dvakrát ako tretí najvplyvnejší parameter. V piatich prípadoch bolo možné pozorovať, že významný vplyv na predikciu hrubého spreadu mal výber konkrétneho upisovateľa (*CREDIT_AGRICOLE*, *DEUTSCHE_BANK*, *WELLS FARGO*, *BNP_PARIBAS*). Pri konkrétnych upisovateľoch bolo možné potvrdiť, že sa jedná o upisovateľov, ktorí sa dlhodobo a každoročne pohybujú medzi TOP15 upisovateľmi v závislosti od upísaného objemu.

Dvakrát sa medzi troma najvplyvnejšími parametrami vyskytol výber syndikátu upisovateľov (*syndicate_1* a *syndicate_2*). Pri oboch syndikátoch bolo možné tvrdiť, že sa jedná o upisovateľov, ktorí sa dlhodobo pohybujú medzi TOP10 upisovateľmi v závislosti od upísaného objemu, ako bolo prezentované v prvej podkapitole analytickej časti práce. Vo všeobecnosti bolo možné konštatovať, že každý trh (v závislosti od regiónu a odvetvia priemyslu) vykázal odlišnú významnosť parametrov determinujúcich predikciu výšky hrubého spreadu. Tri najvplyvnejšie parametre pre každú zo vzoriek s $R^2 \geq 0.75$, sú uvedené v **Tabuľke 10**, pričom označenie vzorky je vyjadrené číslom z **Tabuľky 9**. Celý zoznam významných parametrov pre jednotlivé vzorky sa nachádza v prílohe, časť E.

Tabuľka 10 Najvýznamnejšie parametre vo výsledných modeloch

vzorka	parameter 1	parameter 2	Parameter 3
1	fitch_rating 0.65	os 0.28	maturity 0.04
2	RANK_syndicate 0.37	QUARTILE_syndicate_lag 0.14	number_uw 0.14
3	s&p_rating 0.26	syndicate_1 ² 0.07	EAGG.PA 0.06
4	volume_USD 0.7	maturity 0.11	WELLS_FARGO 0.06
5	CREDIT_AGRICOLE 0.31	UW_top10_syndicate 0.27	moody's_rating 0.17
6	s&p_rating 0.54	UW_top10_syndicate 0.16	currency_USD 0.10
7	QUARTILE_syndicate_lag 0.74	UW_top20_syndicate 0.07	BNP_PARIBAS 0.07
8	s&p_rating 0.29	DEUTSCHE_BANK 0.16	COC 0.11
9	moody's_rating 0.85	country_SOUTH_AFRICA 0.13	maturity 0.01
10	moody's_rating 0.13	syndicate_2 ³ 0.11	s&p_rating 0.08
11	RANK_syndicate_lag 0.51	UW_top20_syndicate 0.22	WELLS_FARGO 0.06
LEGENDA VZORIEK 1. Ázia_Železnice, 2. Sev.Amerika_Širokopásmové pripojenie, 3. Sev.Amerika_Elektronika, 4. Sev.Amerika_Letecký a lodný priem., 5. Ázia_Telekomunikácie, 6. Ázia_Chemický priem., 7. Ázia_Materiály vo výrobe, 8. Sev.Amerika_Priemyselná technika, 9. CEEMEA_Chemický priem., 10. Sev.Amerika_Zdravotníctvo a Farmácia, 11. Sev.Amerika_Obrana			

Zdroj: Vlastné spracovanie.

² syndicate_1 JP_MORGAN_MORGAN_STANLEY

³ syndicate_2 BANK_OF_AMERICA_BARCLAYS_CITIGROUP_GOLDMAN_SACHS

4.3.5 Klasifikácia výšky hrubého spreadu na základe parametrov

Nasledujúca podkapitola sa venuje výsledkom klasifikácie hrubého spreadu. V snahe zvýšiť presnosť modelov využitím iných algoritmov, sme pristúpili k diskretizácii závislej premennej hrubý spread. Nakoľko algoritmus C5.0 vyžaduje aby závislá premenná mala kategorický charakter. Z uvedené vyplýva, že bolo nutné zatriediť pozorované hodnoty hrubého spreadu do kategórií. Pri tvorbe klasifikačného stromu sme vytvorili päť vzoriek, ktorých odlišnosť spočívala v rozsahu výšky hrubého spreadu v rámci vytvorených tried. Pri vzorkách, kde bol hrubý spread triedený na základe kvartilov, kvantilov a decilov, boli všetky hodnoty hrubého spreadu zoradené od najväčšej po najmenšiu a následne priradené do jednotlivých tried. Pri vzorkách, kde bol hrubý spread triedený na základe kvartilov, kvantilov a decilov, boli všetky hodnoty hrubého spreadu zoradené od najväčšej po najmenšiu a následne priradené do jednotlivých tried. Pri vzorkách s označením *group1* a *group2* išlo o modifikáciu vyššie uvedených triedení. Ich opis môžete nájsť v prílohe, časť F. Výsledkom klasifikácie bolo stanovenie pravidiel pre odhad výšky hrubého spreadu. Najlepšie dosiahnuté výsledky boli zaznamenané pri použití klasifikačného algoritmu C5.0 na vzorke, kde bol hrubý spread zatriedený do kvantilov. Dosiahnutá presnosť klasifikácie jednotlivých prípadov bola v tomto prípade 85.42%, ako je možné vidieť z uvedených výsledkov v **Tabuľke 11**.

Tabuľka 11 Presnosť klasifikácie v závislosti od triedenia hrubého spreadu a metódy


vzorka	počet tried	presnosť C5.0	presnosť XGBoost	presnosť CHAID
kvartil	4	87.11%	82.64%	67.2%
kvantil	5	85.42%	83.03%	61.08%
decil	10	76.84%	85.36%	52.43%
group1	3	82.9%	81.01%	69.92%
group2	4	82.76%	82.22%	68.55%

Zdroj: Vlastné spracovanie.

Výsledky klasifikačného algoritmu potvrdili výsledky dosiahnuté v podkapitole 4.3.4. Ako najvýznamnejší parameter pre klasifikáciu výšky hrubého spreadu sa ukázal rating emisie, objem emisie, nasledovaný odvetvím priemyslu, regiónom emisie a splatnosťou. Za uvedenými základnými parametrami sa vyskytli parametre, ktoré

obsahovali informáciu o konkrétnom syndikáte upisovateľov, alebo upisovateľovi emisie. Zoznam desiatich najvýznamnejších parametrov klasifikačného stromu sa nachádza v prílohe, časť F. Prvým uzlom (*Node 0*), ktorý bol v klasifikačnom strome pozorovaný bol uzol rozdeľujúci výšku hrubého spreadu na základe udeleného ratingu od agentúry Standard and Poors. Prvých sedem ratingových ohodnotení (AAA až A-) malo v 66.44% prípadov hrubý spread v intervale (0.05; 2.14 >, uvedené v uzle 1 (*Node 1*) na **grafe 17**. Pri ratingových ohodnoteniach od ôsmeho rizikového stupňa (BBB+ až B+) bolo možné pozorovať pomerne rovnomerné rozdelenie klasifikácie hrubého spreadu do jednotlivých kvantilov s najväčším zastúpením 29.04% v intervale (2.15; 3.09 >, uvedené v uzle 466 (*Node 466*) na **grafe 17**.

Graf 17 Klasifikačný strom C5.0 pre výšku hrubého spreadu: Počiatočný uzol




Zdroj: Vlastné spracovanie.

V nasledujúcich úrovniach klasifikačného stromu, ktoré sa nachádzajú na **grafe 18** sme pozorovali vetvu, vedúcu z uzlu 1. Ďalším pozorovaným parametrom bol výskyt upisovateľa *BANK_OF_CHINA*. V prípadoch, kde sa daný upisovateľ vyskytoval bola vo viac ako 44% prípadov výška hrubého spreadu klasifikovaná do druhého kvartilu, zatiaľ čo v prípadoch ak daný upisovateľ nebol súčasťou IPO, bola výška hrubého spreadu klasifikovaná v prvom kvartile vo viac ako 69% prípadov. *BANK_OF_CHINA* nebol upisovateľom v 4754 pozorovaniach a v takom prípade bol v nasledujúcom uzle 2 hrubý spread klasifikovaný do kvartilu na základe najlepšie umiestneného upisovateľa v syndikáte v závislosti od ročne upísaného objemu. Výsledky ukázali, že syndikáty, kde bol najlepšie postavený upisovateľ v rebríčku do 31. miesta, hrubý spread pochádzal vo viac ako 69%

pozorovaniach z prvého kvartilu, nasledovaný druhým kvartilom (*Node 3*). Pri syndikátoch, kde bol najlepšie postavený upisovateľ vyššie ako na 31. pozícii bol hrubý spread vo viac ako 36% prípadov klasifikovaný do tretieho kvartilu, nasledovaný štvrtým kvartilom.

Graf 18 Klasifikačný strom C5.0 pre výšku hrubého spreadu: pokračovanie



Zdroj: Vlastné spracovanie.

Pri vyhodnocovaní výsledkov klasifikačného stromu vo vetve, ktorá klasifikuje emisie na základe delenia podľa ratingu od Standard and Poors bolo zistené, že existuje značná miera diskrepancie medzi udelenými ratingami od zmienenej ratingovej agentúry a agentúry Moodys, vo vetve, ktorá nasleduje po delení na základe parametra

BestRank_syndicate. V klasifikačnom strome sa na štvrtej úrovni objavuje uzol, ktorý ďalej klasifikuje výšku hrubého spreadu podľa kreditného ratingu od agentúry Moodys. Avšak daný uzol obsahoval delenia na ratingy presahujúce siedmy stupeň, kde maximom bolo ohodnotenie 14 (B1), čo predstavuje špekulatívne dlhopisy značne za úrovňou investičných dlhopisov. Pri dlhopisoch, kde sa uvedené ratingy od kreditných agentúr zhodovali a teda pochádzali z intervalu rizikových stupňov 1 až 7, bol ďalším rozhodujúcim parametrom pre klasifikáciu hrubého spreadu región emisie a následne základné parametre dlhopisov ako je splatnosť (Severná Amerika) alebo objem emisie (Západná Európa). Pri ratingoch, kde panoval nesúlad, sa dlhopisy na nasledujúcej úrovni taktiež klasifikovali na základe regiónu, bolo však možné pozorovať odlišné kvartily hrubého spreadu pre jednotlivé dlhopisy. Na rozdiel od dlhopisov, kde bol pozorovaný súlad udeleného ratingu, bol v tomto prípade na nasledujúcej úrovni najdôležitejším parametrom konkrétny upisovateľ, resp. syndikát. Na základe výsledkov sme boli schopní stanoviť 164 pravidiel pre klasifikáciu výšky hrubého spreadu. Pravidlá spolu s časťou klasifikačného stromu je možné nájsť v prílohe, časť F.

4.4 Analýza hrubého spreadu, preupísanosti a upisovateľov


Nasledujúca kapitola prezentuje výsledky, keď bola analyzovaná vzorka dlhopisov, ktoré boli definované ako preupísané a to aj s mierou preupísanosti. Bol testovaný vzťah medzi mierou preupísanosti a hrubým spreadom pozorovaným pri preupísaných emisiách. Následne bolo vykonané testovanie vzťahu medzi mierou preupísanosti a upisovateľmi emisie. Vzorka na ktorej sme vykonali spomínané analýzy bola tvorená z 1699 pozorovaní na trhu investičných podnikových dlhopisov.

4.4.1 Testovanie vzťahu medzi hrubým spreadom a mierou preupísanosti

Za účelom vykonania analýzy vzťahu medzi hrubým spreadom a mierou preupísanosti bolo nutné rozhodnúť o vytvorení k-tried pre premennú miera preupísanosti (*os_rate*). Aby sme čo najlepšie zachytili pozorovania v analyzovanej vzorke, vytvorili sme sadu štyroch podvzoriek, v ktorej bola miera preupísanosti kategorizovaná do triedy na základe: príslušnosti ku kvartilu, kvantilu, decilu a jednotkovej miere preupísanosti, resp. jej modifikácii (*os_group1*, *os_group2*). Kategorizované miery preupísanosti boli následne testované vo vzťahu k hrubému spreadu. Na základe dosiahnutých výsledkov bolo možné konštatovať, že boli pozorované štatisticky signifikantné rozdiely v hrubom spreade medzi skupinami zastupujúcimi mieru preupísanosti a to pri rozdelení vzoriek podľa všetkých

vyššie uvedených kritérii (kvartil, kvantil, decil a jednotková miera preupísanosti, resp. jej modifikácia (*os_group1*, *os_group2*)). V prílohe, časť G možno nájsť sumár jednotlivých testovaných podvzoriek, obsahujúci opis jednotlivých vytvorených tried, rovnako tak aj vykonanú post-hoc analýzu pre párové porovnanie jednotlivých tried v rámci kvantilov testovaných v hypotézach H15 až H19. Rozdelenie do kvantilov sme si zvolili preto, lebo pri tomto rozdelení závislej premennej bol klasifikačný model C5.0 najpresnejší. Výsledky prezentované na **grafe 19** zobrazujú rozdielnosť prostrednej hodnoty aj variability hrubého spreadu v závislosti od kvantilu, do ktorého spadá miera preupísanosti. Z výsledkov bolo možné konštatovať, že čím vyššia miera preupísanosti bola pozorovaná, tým vyššia bola hodnota hrubého spreadu upisovateľa, kým prostredná hodnota v piatom kvantile bola 3.20%, v treťom kvantile 2.45% a v prvom kvantile 2.19%.

Graf 19 Box plot analýza hrubého spreadu a tried miery preupísanosti




Zdroj: Vlastné spracovanie.

Po vykonaní post hoc analýzy a párovom porovnaní bol na predikciu miery preupísanosti použitý algoritmus CHAID s použitím všetkých parametrov. Na základe dosiahnutých výsledkov bolo možné konštatovať, že v prípade predikcie miery preupísanosti bol najdôležitejším faktorom, podľa ktorého rozhodovací strom CHAID postupoval bol objem emisie. Rozhodovací strom je uvedený na **grafe 20**. Z rozhodovacích uzlov (*Node 1*, *4* a *5*) môžeme pozorovať predikovanú hodnotu miery preupísanosti, ktorá s rastúcim objemom klesá. Druhým faktorom, na základe ktorého bola miera preupísanosti predikovaná

bol hrubý spread. Ak je objem emisie dlhopisov ≤ 349.2 mil. USD a výška hrubého spreadu je $\leq 2.22\%$, predikovaná miera preupísanosti emisie je 4.5, kým v prípade, ak bol hrubý spread $> 2.22\%$, predikcia miery preupísanosti je 6.5. Podobný trend v súvislosti s hrubým spreadom bol pozorovaný aj v prípadoch, keď objem emisie bol v intervale $(790; 1066.42]$, resp. > 1066.42 mil. USD a teda s rastúcou výškou hrubého spreadu bola predikovaná vyššia miera preupísanosti. V prípade emisií, ktorých objem bol > 1066.42 mil. USD, bolo pomocou rozhodovacieho stromu možné spresniť predikciu preupísanosti na základe odvetvia priemyslu, v ktorom emitujúci podnik pôsobí. Týmto spôsobom boli identifikované sektory, v rámci ktorých dochádza k nižšej preupísanosti. Konkrétne išlo o sektory: Ropný priemysel, Potraviny/Nápoje/Tabakové výrobky, Priemyselné strojárstvo, Telekomunikácie a Energetický sektor (elektrina a plyn). V rámci daných odvetví bola predikovaná miera preupísanosti v intervale $<2.7; 3.4]$, kým v odvetviach: Ťažobný priemysel, Finančné služby, Letecký a lodný priemysel a Elektornika bola predikovaná miera preupísanosti 5.

Graf 20 Rozhodovací strom: predikcia miery preupísanosti



Zdroj: Vlastné spracovanie.

4.4.2 Klasifikácia miery preupísanosti emisie

Za účelom klasifikácie, analýzy, štruktúr a miery preupísanosti na primárnom dlhopisovom trhu sme jednotlivé vytvorené vzorky z predchádzajúcej podkapitoly testovali troma rozličnými metódami strojového učenia. Najpresnejšia klasifikácia miery preupísanosti bola dosiahnutá na všetkých testovaných vzorkách s využitím klasifikačného stromu C5.0. Pri hodnotení dosiahnutých výsledkov boli najpresnejšie výsledky dosiahnuté,

ak bola miera preupísanosti rozdelená podľa vzorky do kvantilov, čo umožnilo presnosť klasifikácie na úrovni 83.86%, ako je uvedené v **Tabuľke 12**.

Tabuľka 12 Presnosť klasifikácie v závislosti od podvzorky a použitej metódy


vzorka	počet tried	presnosť C5.0	presnosť XGBoost	presnosť CHAID
kvartil	4	81.73%	51.61%	44.90%
kvantil	5	83.86%	53.18%	49.27%
decil	10	72.40%	22.06%	19.96%
group1	10	73.81%	28.82%	26.21%
group2	5	80.39%	39.12%	35.01%

Zdroj: Vlastné spracovanie.

Pri pozorovaní výsledkov klasifikačného stromu, ktorý je uvedený na **grafe 21** sme mohli potvrdiť, že prvý uzol bol rozdelený na základe konkrétneho upisovateľa *CHINA_MERCHANTS_BANK* (CMB) do uzlov *Node 1* (daný upisovateľ sa vyskytol v emisii) a *Node 17* (upisovateľ nebol súčasťou emisie). V 39 prípadoch, keď bol CMB súčasťou emisie bolo takmer 35% prípadov klasifikovaných do štvrtého a piateho kvantilu miery preupísanosti, čo predstavovalo viac ako 70% prípadov. Pri pozorovaní výsledkov v *Node 17* je možné konštatovať, že ak upisovateľom nebol CMB, zo štvrtého a aj z piateho kvantilu miery preupísanosti pochádza približne 38% prípadov. Ďalším pozorovaným faktorom v prípade, ak bol súčasťou syndikátu upisovateľov CMB, na základe, ktorého bola preupísanosť klasifikovaná je premenná vyjadrujúca počet vzťahov medzi emitentom a syndikátom, ktorý danú emisiu upisoval (*rel_issuer_uw*). V tomto prípade bolo možné konštatovať, že emitenti, ktorí si na IPO vybrali CMB, a ich počet vzťahov so syndikátom upisovateľov bol >451, mali len miery preupísanosti z prvého kvantilu.

Ďalšími hlavnými faktormi v hlavnej vetve klasifikačného stromu bol výskyt upisovateľa *RABOBANK* (*Node 17*) a počet emisií daného emitenta v danom roku *issuer_appear* (*Node 21*) a odvetvie ekonomiky, z ktorého emitent pochádza (*Node 22* a *Node 728*). Pri upisovateľovi *RABOBANK* bolo možné pozorovať, že jeho účasť na emisii zvyšuje mieru preupísanosti z tretieho a štvrtého kvantilu v porovnaní so situáciou, ak sa daný upisovateľ emisie nezúčastnil.

Graf 21 Klasifikačný strom C5.0 pre preupísanosť: Počiatočný uzol




Zdroj: Vlastné spracovanie.

Pri pokračovaní v hodnotení výsledkov klasifikačného stromu C5.0, uvedenom na **grafe 22**, sme sa zamerali na uzol 21 (Node 21), v ktorom sa klasifikácia miery preupísanosti delí na základe počtu emisií emitenta za rok (*issuer_appear*) do uzlov Node 22 a Node 728 a v oboch z pozorovaných uzlov nasledujú uzly klasifikujúce mieru preupísanosti na základe príslušnosti emitenta k odvetviu, v ktorom podnik pôsobí. Z dosiahnutých výsledkov prezentovaných na **grafe 22** bolo možné konštatovať, že do úrovne Node 21 sa pravdepodobnosť vyššej miery preupísanosti vyskytovala pri emitentoch, ktorý sa na primárnom dlhopisovom trhu za rok vyskytli maximálne trikrát. Najväčšie zastúpenie mali emisie, ktoré boli preupísané viac ako šesťkrát, čo zodpovedalo 24.42 percentám prípadov. Naopak, pri emitentoch, ktorí za rok uskutočnili IPO štyrikrát a viac, bola miera preupísanosti klasifikovaná v nižších rozpätiah (kvantiloch), ako je možné pozorovať v Node 728. V nasledujúcich uzloch Node 47 a Node 730 bola miera preupísania klasifikovaná na základe príslušnosti k odvetviu priemyslu. Vo vzorkach máme definovaných 28 odvetví, znázornenie rozdelenia preupísanosti každého z nich prekračuje rámec tejto práce. Pre demonštrovanie klasifikačných pravidiel sme si vybral niekoľko odvetví. Išlo konkrétne o podniky pôsobiace v oblasti ťažobného priemyslu (*Basic_Materials_Mining*). Aj na základe klasifikácie podľa odvetvia priemyslu bolo možné pozorovať, že emitenti, ktorí sa na primárnom trhu podnikových vyskytujú trikrát a menej,

pravdepodobnosť miery preupísania ich emisie bude vyššia ako v prípade tých podnikov, ktoré sa na trhu vyskytnú štyrikrát a viac.

Graf 22 Klasifikačný strom C5.0 pre preupísanosť: Uzol 21




Zdroj: Vlastné spracovanie.

Ďalším zistením prezentovaným na **grafe 22** bolo, že aj v rámci zhody odvetvia priemyslu sa vyskytujú rozdielne faktory, na základe ktorých je klasifikovaná miera preupísanosti. V prípade ťažobného priemyslu sme v rámci emitentov emitujúcich do trikrát ročne, faktorom bol výskyt upisovateľa *SOCIETE_GENERALE*. Ak sa daný upisovateľ zúčastnil emisie (*Node 48*), boli pozorované dva prípady miery preupísanosti z prvého kvantilu a jeden prípad z tretieho kvantilu. V prípade, ak sa jednalo o emitenta pochádzajúceho z ťažobného priemyslu, vyskytujúceho sa na primárnom dlhopisovom trhu viac ako štyrikrát ročne, bol faktorom jeden zo základných parametrov emisie a to splatnosť dlhopisu (*maturity_years_rounded*, *Node 731* a *Node 732*). V danom prípade bolo možné

vysloviť záver, že krátkodobejšie dlhopisy splatné do piatich rokov vrátane obsahovali menej preupísaných emisií, rovnako tak výskyt miery preupísanosti z prvého kvantilu bol najčastejší. **Graf 23** pokračuje v rovnakej vetve ako predchádzajúci, rozdielom je analyzované odvetvie priemyslu, tentokrát sú zobrazené rozdiely v rámci odvetvia priemyselných konglomerátov (*Industrials_Conglomerate*).

Graf 23 Klasifikačný strom C5.0 pre preupísanosť: Uzol 21 (pokračovanie)




Zdroj: Vlastné spracovanie.

Výsledky opätovne ukázali, že pri menej častých opakovaníach emisií v priebehu roka, je zastúpenie vyššej miery preupísanosti vyššie. V rámci zobrazeného odvetvia priemyselných konglomerátov (*Node 242* a *Node 783*) boli opäť pozorované rozdielne faktory pri rozdielnej periodicite výskytu emitenta. V prípade počtu emisií do trikrát ročne je faktorom účasť upisovateľa *BARCLAYS*. Ak sa daný upisovateľ emisie zúčastnil, boli pozorované celkovo len dve emisie, v ktorých sa vyskytla preupísanosť a jej miera pochádzala výhradne z prvého kvantilu. Vo vetve, ktorá klasifikuje emitentov emitujúcich viac ako štyrikrát ročne (*Node 783*) je nasledujúcim faktorom hrubý spread (*UW_spread(%)*, *Node 784* a *Node 789*). Následne môžeme na **grafe 24** pozorovať, že ak podnik emitoval dlhopisy v rámci odvetvia energetiky (*Utilities_&Power_Electricity_&Gas*), aj v tomto prípade, je absolútna početnosť 187 (*Node 588*) preupísaných emisií vo vetve, ktorá obsahuje emitentov emitujúcich do trikrát ročne vyššia, ako v prípade, ak podnik emituje viac ako trikrát ročne (*Node 872*), kedy bolo možné sledovať 29 emisií. Pri porovnávaní daných uzlov *Node 588* a *Node 872*, je možné sledovať takisto, že v prípade, ak podnik emituje viac ako trikrát ročne, výraznejšie je zastúpená miera preupísania pochádzajúca z prvého a druhého

kvantilu, naopak, v prípade maximálne troch emisií ročne v energetickom sektore sa miera preupísanosti najčastejšie vyskytuje v treťom kvantile.

Graf 24 Klasifikačný strom C5.0 pre preupísanosť: Uzol 21 (pokračovanie)



Zdroj: Vlastné spracovanie.

Pri ďalšom delení v oboch sledovaných vetvách v uzloch (*Node 589*, *Node 700*, *Node 873*, *Node 882*) bolo možné pozorovať, že faktor klasifikácie miery preupísanosti bol totožný – početnosť výskytu daného syndikátu upisovateľov (*syndicate_count*). Rozdielna bola však hranica, na základe ktorej je miera preupísanosti klasifikovaná. V prípade emitentov emitujúcich do trikrát ročne, bola rozhodujúcou hodnotou pre klasifikáciu hranica početnosti výskytu syndikátu 7, kým pre podniky emitujúce viac ako trikrát ročne bola hranica početnosti výskytu syndikátu 2. Uzol (*Node 700*) zobrazuje klasifikáciu, ak bola početnosť výskytu upisovateľov > 7 a zároveň emitent neemitoval viac ako tri dlhopisy ročne, tak v takom prípade bolo 100% prípadov klasifikovaných do piateho kvantilu miery preupísanosti, resp. viac ako päťkrát preupísanú emisiu. Naopak, ak bola početnosť výskytu syndikátu ≤ 7 , miera preupísanosti bola rozložená výraznejšie rovnomernejšie, s najväčším zastúpením tretieho kvantilu miery preupísanosti. Najvýznamnejším parametrom v klasifikačnom strome pre mieru preupísanosti bolo odvetvie ekonomiky (*category*), v ktorom emitent pôsobí. Hodnota dôležitosti dosiahla hladinu 0.0289. Druhým najvplyvnejším parametrom bol objem emisie (*volume_USD*), na úrovni 0.0252. Následne sa výnimkou parametra vyjadrujúceho splatnosť dlhopisu (*maturity_years_rounded*) vyskytujú iba parametre, ktoré súvisia s konkrétnym upisovateľom, alebo syndikátom upisovateľov. Pri hodnotení výsledkov dôležitosti parametrov klasifikujúcich mieru

preupísanosti bolo možné pozorovať, že rozdiely medzi dôležitosťou jednotlivých parametrov nevykázali obdobne veľké rozdiely, ako to bolo v prípade dôležitosti pri predikcii hrubého spreadu, nakoľko významnosť dvadsiatich najvplyvnejších parametrov sa vyskytovala na intervale $<0.0181 ; 0.0289>$, graf je uvedený v prílohe, časť H. Na základe vyššie uvedených modelov sme mohli definovať pravidlá, ktoré klasifikujú mieru preupísanosti. Pre stručnosť boli vo výsledkoch práce uvedené iba pravidlá klasifikujúce emisie spadajúce do kategórie s označením "0". Ide o najnižšiu kategóriu preupísanosti. V tejto kategórii sa pohybuje preupísanosť v intervale od 0.6 až po 1.99 krát (preupísaný dlhopis). Celkovo sme na základe výsledkov definovali 93 pravidiel. Kompletne definované pravidlá sú uvedené v prílohe, časť F.

Pravidlo 1: Ak hodnota „issuer_appear“ je v rozsahu 1 až 2 a hodnota „UW_spread(%)“ je menšia alebo rovná 1.380 a hodnota „odvetvie“ je „Consumer_Goods_&_Services,_Foodstuffs//Tobacco“ a hodnota „CUC“ je menšia alebo rovná 0 a hodnota „NATWEST_MARKETS“ je menšia alebo rovná 0, potom trieda je 0.

Pravidlo 2: Ak hodnota „issuer_appear“ je v rozsahu 1 až 2 a hodnota „odvetvie“ je „Infrastructure,Air&Ports“ a hodnota „VIX_market_status“ je „worsening“ a hodnota „VCIT_market_status“ je buď „neutral“ alebo „worsening“ a hodnota „DBS_BANK“ je menšia alebo rovná 0 a hodnota „BARCLAYS“ je väčšia ako 0, potom trieda je 0.

Pravidlo 3: Ak hodnota „odvetvie“ je „Infrastructure,_Roads/“ a hodnota „COC“ je väčšia ako 0 a hodnota „CREDIT_AGRICOLE“ je menšia alebo rovná 0, potom trieda je 0.

Pravidlo 4: Ak hodnota „issuer_appear“ je v rozsahu 3 až 4 a hodnota „UW_spread(%)“ je menšia alebo rovná 0.66 a hodnota „odvetvie“ je „Manufacturing,_Auto“ a hodnota „RABOBANK“ je 0 potom trieda je 0.

Pravidlo 5: Ak hodnota „odvetvie“ je „Basic_Materials,_Mining“ a hodnota „VCIT_market_status“ je „worsening“, potom trieda je 0.000.

Pravidlo 6: Ak hodnota „issuer_appear“ je 1 a hodnota „odvetvie“ je „Media_&_Telecoms“ a hodnota „VIX_market_status“ je „neutral“, potom trieda je 0.

Pravidlo 7: Ak hodnota „issuer_appear“ je 2 a hodnota „odvetvie“ je „Utilities_&_Power,_Water/ Waste“, potom trieda je 0.

Pravidlo 8: Ak hodnota „odvetvie“ je „Basic_Materials,Oil&_Gas“ a hodnota „VCIT_market_status“ je „worsening“ a hodnota „BANK_OF_COMMUNICATIONS“ je väčšia ako 0, potom trieda je 0.

Pravidlo 9: Ak hodnota „issuer_appear“ je v rozsahu 3 až 4 a hodnota „region“ je „Western_Europe“ a hodnota „odvetvie“ je „Transport_&_Logistics“, potom trieda je 0.

Pravidlo 10: Ak hodnota „odvetvie“ je „Consumer_Goods_&_Services“, a hodnota „UW_syndicate_ UW_TOP15“ je 1, potom trieda je 0.

5 Diskusia

Rozbor výsledkov výskumu uvedeného v práci rozdelíme do troch hlavných častí. V prvej časti stručne zosumarizujeme dosiahnuté výsledky súvisiace s formulovanými čiastkovými cieľmi a výskumnými otázkami práce. V druhej časti tejto kapitoly budeme formulovať prínosy a odporúčania využiteľné pre prax. Na záver diskusie budeme konštatovať vedecké prínosy práce a možnosti pre ďalšie smerovanie výskumu v skúmanej problematike.

Na základe výsledkov práce sme mohli potvrdiť, že trh podnikových dlhopisov je značne diverzifikovaný pri pohľade na ranking dlhopisov. Rozdiely medzi prostrednými hodnotami hrubého spreadu investičných (2.6%), crossover (6%) a neinvestičných dlhopisov (9.3%) sú v sledovanom období signifikantné, z toho dôvodu boli pre analýzu vybrané iba podnikové dlhopisy, ktoré spadajú do kategórie „*investičné*“. Pri charakteristike vývoja primárneho trhu môžeme potvrdiť, že z celkového počtu 349 upisovateľov bolo 80% emitovaného objemu dlhopisov upísaných 17 upisovateľmi. Môžeme potvrdiť, že v tomto prípade je trh značne koncentrovaný, keďže necelých 5% upisovateľov ovláda 80% trhu. Pri analýzach regiónov emisie sme mohli potvrdiť, že 92% podnikových investičných dlhopisov je emitovaných v regióne Severnej Ameriky (60%) a Západnej Európy (32%).

Následne sme v analytickej časti práce vykonali štatistické testovania vzťahov medzi hrubým spreadom a parametrami dlhopisu, ktoré sme rozdelili do dvoch kategórií. Prvou kategóriou boli parametre označené ako *základné*. Na tieto parametre nemá vplyv upisovateľ a popisujú základné parametre emisie, trhové skutočnosti a externé faktory emisie. Pri štatistickom testovaní bolo testovaných sedem základných hypotéz, testujúcich rovnaké rozdelenie hrubého spreadu v rámci skúmaných parametrov a ich kategórií (mena emisie, spread benchmark, región emisie, rok emisie, ratingové ohodnotenia). Všetky zo stanovených základných hypotéz sme mohli zamietnuť, rovnako ako aj subhypotézy, ktoré slúžili na porovnávanie dvojíc kategórií jednotlivých parametrov. Môžeme potvrdiť, že hrubý spread sa v závislosti od daných parametrov líši a na výšku poplatku, ktorý emitent za emisiu zaplatí majú štatisticky významný vplyv. Naše tvrdenie sme potvrdili aj v následných podkapitolách, keď sme testovali vzťah medzi hrubým spreadom a parametrami emisie pri definovaných externých faktoroch, kde sa základné parametre objavili medzi najvplyvnejšími.

Pri testovaní štatistickej závislosti môžeme potvrdiť výskyt štatisticky významných vzťahov, v prípade Spearmanovho poradového korelačného koeficientu a pozitívnym vzťahom medzi hrubým spreadom a ratingovým ohodnotením. Najsilnejší vzťah hrubého spreadu podnikových investičných dlhopisov (0.55) bol pozorovaný pri ratingovom ohodnotení od Standard and Poors ($n = 10,148$), kým pri agentúre Moodys bol vzťah o stotinu nižší (0.54) a rovnako tak menšia početnosť podnikových dlhopisov s udeleným ohodnotením od Moodys ($n = 9,824$). Pri testovaní ostatných základných parametrov (objem emisie, splatnosť) a ich závislosti voči hrubému spreadu bolo *Spearmanovým* korelačným koeficientom potvrdená štatistická významnosť, avšak nízke hodnoty korelačného koeficientu (objem emisie -0.1; splatnosť 0.2) nám neumožňujú potvrdiť existenciu silných väzieb medzi premennými.

Výsledky práce, ktoré testovali vzťah medzi hrubým spreadom a druhou skupinou parametrov, ktoré súviseli s upisovateľom a jeho reputáciou a postavením na trhu potvrdili taktiež štatisticky významné rozdiely. Celkovo bolo testovaných sedem základných hypotéz, z ktorých bolo šesť možno zamietnuť. Rovnako tak výsledky post hoc analýzy, v ktorých bolo testovaných štrnásť subhypotéz a bolo možné zamietnuť trinásť. Na základe týchto výsledkov môžeme potvrdiť, že existuje štatisticky významný rozdiel medzi rozdelením hrubého spreadu naprieč kategóriami, ktoré vyjadrujú postavenie a reputáciu upisovateľa na trhu (ako napr. postavenie upisovateľa v závislosti od upísaného objemu, či počtu emisií v ktorých sa zúčastnil). V prípade, ak sa na náklady emisie pozeráme len cez jedného konkrétneho upisovateľa a zoradíme upisovateľov do poradia na základe upísaného objemu za každý jeden z pozorovaných rokov, môžeme potvrdiť, že výška hrubého spreadu je najvyššia, ak si emitent vyberie upisovateľa z prvej päťky upisovateľov. Prostredná hodnota hrubého spreadu sa v tomto prípade pohybuje na úrovni 2.36%. Prostredná hodnota hrubého spreadu následne klesá na úroveň 2.03% v prvej dvadsiatke upisovateľov. Na základe uvedeného konštatujeme, že reputácia upisovateľa predstavuje parameter, ktorý má vplyv na výšku hrubého spreadu a s klesajúcou reputáciou klesá aj výška hrubého spreadu. Pri skúmaní štatistickej závislosti hrubého spreadu a parametrov súvisiacich s upisovateľom bola potvrdená štatistická významnosť, avšak hodnoty korelačných koeficientov blízke nule nám neumožňujú vysloviť závery týkajúcej sa existencie vzťahov.

Dosiahnuté výsledky v rámci predikcie výšky hrubého spreadu za pomoci využitia regresného stromu XGBoost nám umožňujú konštatovať, že z analyzovaných parametrov, ktoré majú vplyv na výšku hrubého spreadu patria vo všeobecnosti *základné parametre*

dlhopisu ako je ratingové ohodnotenie emitenta od agentúr Standard and Poors a Moodys, nasledované splatnosťou, trhovými podmienkami a regiónom emisie. V tomto prípade je však nutné poznamenať, že pri predikcii, ktorá zahŕňa celý trh sú regresné metriky pomerne vysoké, vykazujúc chybu v predpovedi RMSE na úrovni 0.92% a takisto koeficient determinácie len mierne prevyšujúci hladinu 0.5, konkrétne na úrovni 0.54. Za účelom zlepšenia presnosti predpovede modelu boli vytvorené vzorky, ktoré boli definované externými faktormi, ktoré podnik ovplyvniť nemôže a to región v ktorom emituje a takisto odvetvie priemyslu v ktorom vykonáva podnikateľskú aktivitu. Takýmto spôsobom sme dokázali zlepšiť presnosť predikcie výšky hrubého spreadu. V najlepšom modeli bola zaznamenaná RMSE 0.14%, a koeficient determinácie dosiahol úroveň 0.93. Výsledky ukázali, že významnosť parametrov (v oboch sledovaných skupinách) sa významne líši od externých faktorov, ako sme uviedli (región a odvetvie priemyslu). Môžeme tak konštatovať, že externé faktory, ktoré podnik ovplyvniť nemôže do značnej miery definujú, ktoré parametre budú pre stanovenie hrubého spreadu dôležité. V šiestich z jedenástich analyzovaných vzoriek bol udelený rating emitenta najvýznamnejším parametrom na predikciu. Boli identifikované tri vzorky (*Sev. Amerika_Širokopásmové pripojenie*, *Ázia_Materiály vo výrobe*, *Sev. Amerika_Obrana*), v ktorých boli medzi troma najvplyvnejšími parametrami iba parametre súvisiace s upisovateľom, resp. syndikátom.

Pri vytvorení modelu na klasifikáciu výšky hrubého spreadu bolo potvrdené, že upisovatelia s najvyššou mierou reputácie (prvý až piaty upisovateľ) si účtujú vyšší hrubý spread v porovnaní s ostatnými päťicami upisovateľov v prvej dvadsiatke. Nie sú to však upisovatelia s najvyššou reputáciou, u ktorých je sledovaný najvyšší hrubý spread. Upisovatelia, ktorí sú mimo prvej dvadsiatky a obsluhujú približne 17% trhu, majú v priemere hrubý spread vo výške 2.55%. Okrem iného sme pri klasifikácii hrubého spreadu mohli konštatovať, že v 633 prípadoch, čo je viac ako 5% vzorky, existuje vysoká miera diskrepancie medzi udelenými ratingami od dvoch najväčších kreditných ratingových agentúr Standard and Poors a Moodys. Kým Standard and Poors udelil emitentom kreditné riziko v intervale 1 až 7, v prípade Moodys sledujeme, že rovnakým emitentom udelil rating v intervale 8 až 14, pričom stupne vyššie ako 10 už nemôžu byť klasifikované ako investičné.

V ďalšej časti bol analyzovaný vzťah medzi preupísanosťou a hrubým spreadom a následne medzi preupísanosťou a upisovateľom emisie. Ako sa uvádza aj v odbornej literatúre (Krebbers a kol., 2023), preupísanosť nie vždy vyjadruje, že dlhopis bol podhodnotený, keď je preupísaný pri IPO. Preupísanie emisie dlhopisov pri IPO môže mať

rôzne dôvody a nie všetky z nich sú spojené s (úmyselným) podhodnotením emisie. Preupísanosť ako taká nemusí mať pre emitenta len negatívny vplyv, ale aj pozitívny. Môže to umožniť budúci príliv finančných prostriedkov využiteľný na rôzne účely, ako napríklad rozšírenie podnikania, investície do rastu a vývoja, splácanie dlhov alebo financovanie akvizícií. Zvýšenie kapitálu môže posilniť finančnú pozíciu emitenta a poskytnúť mu väčšiu flexibilitu pri riadení svojho podnikania. Na základe výsledkov môžeme potvrdiť, že pri odhade miery preupísanosti vystupuje ako významný faktor hrubý spread upisovateľa. V nami analyzovanej vzorke ako druhý najvplyvnejší po objeme emisie. V porovnaní so všeobecnými výsledkami sa však v tomto prípade stretávame s opačným trendom a to, že s rastom objemu emisie rastie aj výška hrubého spreadu upisovateľa. Pokiaľ je hrubý spread upisovateľa vyšší ako je stanovená kritická hodnota pre daný objem, s rastúcim hrubým spreadom rastie aj miera preupísanosti. V predikcii miery preupísanosti, ak je objem emisie ≤ 349.2 mil. USD a výška hrubého spreadu je $\leq 2.22\%$, predikovaná miera preupísanosti emisie je 4.5 krát, kým v prípade, ak bol hrubý spread $> 2.22\%$, predikcia miery preupísanosti je 6.5 krát. Následne sme túto skutočnosť mohli potvrdiť aj v prípade objemu emisie bol v intervale $(790; 1066.42 > , \text{mil. USD})$. V tomto prípade sa opäť ako druhý faktor vyskytol hrubý spread a to rozdelený do troch kritických hodnôt: $\leq 1.04\%$, $(1.04\%; 2.94\% > a > 2.94\%$. V tomto prípade rastie predikovaná miera preupísanosti v závislosti od uvedených kritických hodnôt 2.9 krát, 3.6 krát a 4.5 krát. V prípade emisií, ktorých objem > 1066.42 mil. USD, boli identifikované tri totožné kritické hodnoty hrubého spreadu ako pri objemoch emisií v intervale $(790; 1066.42 > , \text{mil. USD})$. Avšak, hodnoty miery preupísanosti boli predikované v hodnotách 2.5 krát, 3.1 krát a 4.8 krát. Z dosiahnutých výsledkov je možné tvrdiť, že predikcia vyššej miery preupísanosti je pravdepodobnejšia pri menších emisiách, ktorých objem je ≤ 349.2 mil. USD. Pri väčších emisiách je sledovaný taktiež podobný jav, až kým výška hrubého spreadu upisovateľa neprekročí hodnotu 2.94%. V danom prípade je možné potvrdiť zistenia o vzťahu medzi hrubým spreadom a objemom emisie, ktorý bol potvrdený aj v odbornej literatúre (Papaioanou a Karagozoglu, 2017; Altinkılıç a Hansen, 2000), keď pri raste objemu emisie hrubý spread klesá až do bodu, kedy upisovateľ musí vynaložiť väčšie úsilie a zdroje na uvedenie emisie na trh a certifikáciu jej hodnoty. V takom prípade variabilné náklady môžu začať rásť, keď objem emisie prekročí určitú úroveň a krivka hrubého spreadu tak opíše tvar U krivky.

Pri klasifikácii miery preupísanosti dlhopisu (resp. jej príslušnosti do kvantilu) medzi dvadsiatimi najvplyvnejšími faktormi boli parametre súvisiace s konkrétnym upisovateľom

zastúpené v najrozšírenejšej miere – 15 identifikovaných faktorov. Základné parametre dlhopisu boli identifikované 3. Najvplyvnejším parametrom je odvetvie priemyslu emitenta, nasledovaný objemom emisie a na deviatom mieste splatnosťou dlhopisu v rokoch. Najvýraznejším rozdielom v porovnaní so vzťahmi pozorovanými pri predikcii výšky hrubého spreadu, ktorý bol pozorovaný pri výsledkoch klasifikácie miery preupísanosti, bola absencia ratingových hodnotení. V tejto časti práce sme zodpovedali výskumné otázky časti práce a to, že môžeme potvrdiť štatisticky významný vplyv vzťahu medzi upisovateľom a emitentom. V stromovej štruktúre klasifikačného stromu je možné taktiež identifikovať rovnaké sektory, v ktorých k preupísanosti prišlo. Rozdielom však je, ako často sa emitent vyskytuje v priebehu roka na trhu. Z výsledkov je zrejmé, že emitenti, ktorí nemajú viac ako tri emisie za rok, dosahujú väčšiu mieru preupísanosti, ako emitenti, ktorí sa na trhu objavujú aspoň štyrikrát ročne. V tomto ohľade sme mohli potvrdiť, že v prípade preupísanosti emisie vystupuje hrubý spread ako jeden z dôležitých faktorov pri predikcii hrubého spreadu ako sme uviedli v podkapitole 4.4.1. Upisovateľ využíva hrubý spread, resp. jeho variabilnú časť ako kompenzáciu za zvýšené úsilie, ktoré musí vynaložiť, aby pre emitenta vygeneroval dopyt medzi investormi.

5.1 Prínosy a odporúčania pre prax

Prínosy dizertačnej práce možno zhrnúť do nasledujúcich bodov: I. Charakteristika vývoja primárneho trhu podnikových dlhopisov, ako aj upisovateľov, ktorý na ňom pôsobia. II. Komparácia základných parametrov emisie a ich vplyv na hrubý spread upisovateľa, kde môžeme na základe dosiahnutých výsledkov potvrdiť, že na výšku nákladov na emisiu majú významný vplyv parametre ako: objem emisie, udelený rating od agentúr Standard and Poors a Moodys a splatnosť dlhopisu. Dôležitými a špecifickými parametrami sa ukázali aj región a odvetvie priemyslu, v ktorom sa emisia dlhopisov uskutočňuje. III. Zhodnotenie vplyvu reputácie upisovateľa na hrubý spread. V tomto prípade môžeme potvrdiť, že za služby „najlepších“, t.j. prvých päť najväčších investičných bánk (BANK OF AMERICA, JP MORGAN, CITIGROUP, GOLDMAN SACHS, BARCLAYS) emitent zaplatí viac, ako v porovnaní s inými investičnými bankami, ktoré sa dlhodobo umiestňujú v prvej dvadsiatke. Pozornosť však treba venovať aj upisovateľom, ktorí sa nachádzajú mimo tzv. TOP20, nakoľko pravdepodobnosť vyššieho poplatku a aj preupísania pri týchto upisovateľoch je vyššia v porovnaní s najlepšími. IV. Identifikácia dôležitosti externých faktorov ovplyvňujúcich výšku hrubého spreadu dlhopisu, ako aj dôležitosť rozdielnych

parametrov emisie. V. Definícia pravidiel, ktoré ovplyvňujú výšku hrubého spreadu upisovateľa. V rámci definovaných pravidiel sme identifikovali upisovateľov, ktorý môžu v určitých sektoroch a za určitých podmienok zvýšiť hrubý spread.

Zo 164 definovaných pravidiel, ktoré boli výsledkom klasifikačného stromu, uvedené v prílohe časť F, pre potreby diskusie vyberáme odporúčania, ktoré sú vhodné pre emitentov v Európe. Všetky uvedené odporúčania sú na základe klasifikačného stromu C5.0 s presnosťou 87.1%.

Doba splatnosti dlhopisu >9 rokov, ale zároveň ≤ 15 , región emisie je Západná Európa, emitent je zo sektora energetiky Elektrina a plyn, v syndikáte upisovateľov nebude väčšie zastúpenie upisovateľov z TOP5 viac ako 44%, upisovateľom nebude CREDIT_SUISSE a DANSKE_BANK, potom bude hrubý spread z intervalu 0.05 – 2.14%.

Doba splatnosti dlhopisu ≤ 15 rokov, hodnota S&P ratingu je 8 alebo 9, región je Západná Európa, emitent je zo sektora energetiky Elektrina a plyn, syndikát BANK_OF_AMERICA_BBVA_CREDIT_AGRICOLE_DEUTSCHE_BANK_GOLDMAN_SACHS_MEDIOBANCA_MORGAN_STANLEY_SANTANDER_SMBC_NIKKO_SOCIETE_GENERALE nie je súčasťou emisie a rovnako tak ani upisovateľ BARCLAYS, potom bude hrubý spread z intervalu 0.05 – 2.14%.

Ak hodnota Moody's ratingu patrí do intervalu [8; 14] a región je Stredná – Východná Európa, Blízky Východ a Afrika, hodnota najlepšie umiestneného upisovateľa v syndikáte je ≤ 31 a upisovateľ STANDARD_CHARTERED bude súčasťou emisie, potom bude hodnota hrubého spreadu z intervalu 3.1 – 4.28%.

Ak objem emisie je > 547 mil. USD, región je Západná Európa, kategória je Výroba -Všeobecná, syndikát BARCLAYS_COMMERZBANK_HSBC_ING_JP_MORGAN nie je súčasťou emisie, rovnako tak v emisii nie sú upisovatelia UBS a BANK_OF_AMERICA, potom bude hrubý spread z intervalu 0.05 – 2.14%.

Ak je doba splatnosti dlhopisu ≤ 15 rokov, región je Západná Európa, kategória je Priemysel, Pivovarníctvo a destilácia, upisovateľ CREDIT_SUISSE nie je súčasťou emisie, potom bude hrubý spread z intervalu 0.05 – 2.14%.

Ak je doba splatnosti dlhopisu ≤ 15 rokov, hodnota S&P ratingu patrí je 8 alebo 9, región je Západná Európa, kategória je Média Telekomunikácie, v syndikáte upisovateľov nebude väčšie zastúpenie upisovateľov z TOP5 viac ako 87.5, v emisii nebude syndikát

BANK_OF_AMERICA_COMMERZBANK_DEUTSCHE_BANK_ING a upisovateľ UBS potom bude hrubý spread z intervalu 0.05 – 2.14%.

Nasledujúce odporúčania sú odvodené od jednotlivých sektorov v ktorých môže emitent pôsobiť. V sektore Média – Telekomunikácie, neodporúčame využívať v emisii služby upisovateľa MEDIOBANCA. V sektore Realitných služieb a REITs neodporúčame výber upisovateľa SOCIETE GENERALE.

Vo všeobecnosti môžeme na základe definovaných pravidiel pre emitentov v regióne Západnej Európy tvrdiť, že emitovanie nižších objemov emisií ako 284.84 mil. USD je spojený s vysokými poplatkami. Ďalej odporúčame pokiaľ sa kreditný rating emitenta udelený od Standard and Poors pohybuje v intervale rizikového stupňa 1 až 7 a od agentúry Moodys v intervale 1 až 4 aby v procese emisie neboli zahrnutí nasledujúci upisovatelia: BANK_OF_CHINA, GAZPROMBANK, BANK_OF_NEW_YORK, DDS_BANK, CITIC, BANK_OF_COMMUNICATIONS, LLBW, CAIXABANK, ANZ, CREDIT_SUISSE a SHANGHAI_PUDONG.

5.2 Vedecké prínosy a smerovanie ďalšieho výskumu

Z vedeckého hľadiska táto práca nadväzuje na uskutočnený výskum autorov (Fang, 2005; Anders, Betzer a Limbach, 2014; Cabo-Valverde a kol., 2016; Xu a kol., 2017; Chen a kol., 2019), ktorí sa venovali vplyvu upisovateľov na primárnom trhu dlhopisov. Je možné potvrdiť, že upisovatelia si nestanovujú výšku hrubého spreadu len na základe základných parametrov ako je objem emisie, splatnosť dlhopisu, ratingové ohodnotenie emitenta, či región a odvetvie. Relevantnými faktormi sú aj predchádzajúce vzťahy s emitentom, prípadne zámer emitenta generovať nadmerný dopyt – preupísanosť. Vykonaný výskum potvrdil, že upisovatelia ktorí majú najvyššiu reputáciu (prvý až piaty) na trhu, si v priemere účtujú hrubý spread vo výške 2.36%, čo je najviac, ak porovnávame upisovateľov obsluhujúcich 80% trhu podnikových dlhopisov. Úplne najvyšší hrubý spread však bol pozorovaný pri upisovateľoch, ktorí neparia do prvej dvadsiatky. Túto skutočnosť je možné vysvetliť napríklad špecifickým trhom (regionálne alebo regulačné hľadisko), kde tí najlepší upisovatelia nemajú prístup k emisiám, resp. len v obmedzenej forme. V takom prípade je možné, že upisovateľ, ktorý v celosvetovom meradle je takmer neznámym a teda jeho reputácia nie je významným parametrom, dokáže na regulovanom trhu operovať s vyššou maržou. Pri analýze úlohy upisovateľov na primárnom dlhopisovom trhu vzhľadom na hrubý spread sme mohli potvrdiť predchádzajúce hypotézy od autorov Altinkılıç a Hansen (2000),

ktorá bola neskôr rozvinutá ďalšími (Papaioanou a Karagozoglu, 2017). Na základe výsledkov bolo možné konštatovať, že upisovatelia, ktorí boli danými autormi definovaní ako „menej kvalitní“ alebo „menší“, v našom prípade upisovatelia mimo najlepšej dvadsiatky realizujú rýchlo rastúce variabilné náklady (ako zložka hrubého spreadu), nakoľko musia na trhu podnikat' pri nižšom rozsahu obchodov a výnosov, pričom daný jav je pozorovaný aj pri preupísanosti.

Pri vyhodnotení časti výsledkov výskumu zameraných na preupísanosť, je možné domnievať sa, že mechanizmus (jav) preupísanosti je pravdepodobne spôsobený nákladným a zložitým vyhľadávaním, ktorému upisovatelia čelia pri hľadaní potenciálnych investorov, podobne ako to definoval aj Hearn (2014), čo je problémom najmä pri podnikoch, ktoré sa na primárnom trhu objavujú prvýkrát alebo veľmi sporadicky. Preupísanie emisie zo strany upisovateľa môže byť úmyselné a to s motiváciou na udržiavanie vzťahov s investormi pre opakované obchody, čím môžeme potvrdiť tvrdenia od autorov predchádzajúcich štúdií (Siani, 2019; Krebbers a kol., 2023), že dopytové šoky sa častejšie vyskytujú v emisiách emitentov, ktorí sa na trhu vyskytujú sporadickejšie ako ostatní. Ďalej sme mohli potvrdiť zistenia od Bessembinder a kol. (2020) že vysoká preupísanosť sa vo väčšine prípadov vyskytuje u upisovateľov, ktorí nepatria medzi najväčších hráčov na trhu a teda v našom prípade nie sú v prvej dvadsiatke a zároveň ide o emitenta, ktorý sa na trhu vyskytol do trikrát. V tomto prípade je možné konštatovať, že dopyt investorov je nižší v prípade nových emitentov, čo vedie k možnému úmyselnému podhodnoteniu emisie a následnému preupísaniu. Dôvodom môže byť aj tvrdenie (Bessembinder a kol. 2020), že úroveň dopytu investorov dlhopisov má dôležité ekonomické dôsledky aj pre emitentov, keďže vysoký dopyt investorov môže urýchliť čas potrebný na ďalšie emisie dlhopisov a taktiež potenciálne znižuje náklady na kapitál podniku pri emisii. Zistenia týkajúce sa preupísanosti u emitentov, ktorý sa na trhu vyskytujú v menšej miere sú v súlade s konštatovaním o dobývaní renty od Clarka (2016), nakoľko upisovatelia využívajú svoju informačnú výhodu, v ohľade na investorov tu sledujeme informačnú asymetriu a využívajú svoje dostupné zdroje pri procese IPO na zabezpečenie výhodného postavenia upisovateľa, čo môžeme považovať za nežiadúce a škodlivé pre voľný trh.

Smerovanie ďalšieho výskumu sa otvára hneď niekoľko možností. Zaujímavou otázkou pri skúmaní vzťahu medzi hrubým spreadom a preupísanosťou by bola alokácia emisie medzi konkrétne typy investorov a následná výkonnosť dlhopisov na sekundárnom dlhopisovom trhu. Pri klasifikácii hrubého spreadu sa objavila značná miera diskrepancie

medzi udelenými ratingovými ohodnoteniami od Standard and Poors a Moodys. V tomto prípade by bolo vhodné testovať, pri akých podmienkach sa dané rozdiely vyskytli a nadviazať na tvrdenia Pertaia a kol. (2021), ktorí konštatovali, že techniky a metódy používané na ohodnotenia od ratingových agentúr sú zastarané a nepresné. Možnosť ako zlepšiť metriky pre predikciu hrubého spreadu vidíme v tom aby sa ratingové agentúry a aj upisovatelia usilovali o väčšiu transparentnosť svojich metodík, kritérií a ratingových procesov. Ratingy by takisto mohli profitovať zo zahrnutia väčšieho množstva výhľadových faktorov, ktoré by zachytávali dlhodobé vyhliadky spoločnosti. To môže zahŕňať okrem tradičných finančných ukazovateľov aj hodnotenie inovačných schopností spoločnosti, jej konkurenčného postavenia a schopnosti prispôbiť sa novým trendom. Ďalším spôsobom, ktorý by pomohol nielen ratingovým agentúram ale aj upisovateľom je využívanie pokročilých technológií, ako je umelá inteligencia a strojové učenie, by mohlo zlepšiť proces tvorby ratingov. Dané technológie môžu pomôcť analyzovať obrovské množstvo údajov, identifikovať vzory a poskytovať presnejšie a včasnejšie hodnotenia pre všetky zainteresované strany.

Záver

Pri súčasných trhových podmienkach, keď na finančných trhoch prevláda zmiešaný sentiment, ovplyvnený najmä udalosťami z roku 2022 a celková nálada je ovplyvnená dozvukmi pandémie COVID, vojnou na Ukrajine, krízou v dodávateľských reťazcoch alebo vysokou infláciou, ponúka nielen pre podniky príležitosť vo väčšej miere opäť financovať svoje aktivity emisiou dlhopisov. Keďže sú to práve dlhopisy, na ktoré sa v období krízy či nepokoja ekonomické subjekty obracajú v snahe získať cudzí kapitál pre investície a refinancovanie. Na základe nielen týchto udalostí je dôležité pochopiť úlohu upisovateľov, ktorí pôsobia ako sprostredkovatelia pri získavaní a alokovaní cudzieho kapitálu. V teoretickej časti práce sme sa z toho dôvodu venovali charakteristike primárneho trhu, upisovateľov a celkovému procesu emisie dlhopisov. V najväčšej miere sme sa v charakteristike venovali jednotlivým javom, ktoré nastávajú pri emisiách a ktoré ovplyvňuje upisovateľ, pričom pozornosť bola venovaná jeho reputácii. Rovnako tak sme sumarizovali predchádzajúci výskum a dosiahnuté výsledky v predmetnej oblasti venujúcej sa upisovateľom. Na základe teoretických výstupov práce sme stanovili dve základné veličiny pre výskum, ktorými boli hrubý spread upisovateľa a preupísanosť. Hrubý spread ako ukazovateľ nákladov na emisiu pre emitenta a preupísanosť ako mieru podhodnotenia emisie.

S cieľom analyzovať úlohu upisovateľov na primárnom dlhopisovom trhu sme v teoretickej časti testovali vzťahy medzi hrubým spreadom a parametrami emisie, ktoré na výšku hrubého spreadu vplyvajú. Bolo potvrdené, že základné parametre dlhopisu a emisie, ako je objem emisie, kreditný rating emitenta, či splatnosť, majú významný vplyv na výšku hrubého spreadu, ktorý upisovateľ pre emitenta stanoví. Následne sme sa venovali upisovateľom a ich reputácii. Reputáciu upisovateľa sme vyjadrili ako postavenie daného upisovateľa v rebríčku upisovateľov pre každý zo sledovaných rokov 2012 až 2022 na základe upísaného objemu emisií. Na základe dosiahnutých výsledkov sme mohli potvrdiť, že pri rozdelení upisovateľov do päťíc podľa upísaného objemu, je možné pozorovať klesajúcu výšku hrubého spreadu. Najvyššia prostredná hodnota hrubého spreadu bola pozorovaná pri upisovateľoch mimo najlepšej dvadsiatky. Ďalej bolo vo výskumnej časti potvrdené, že jednotlivé parametre emisie, ktoré majú vplyv na výšku hrubého spreadu upisovateľa sa značne odlišujú v závislosti od externých faktorov ako je región emisie a odvetvie v ktorom emitent pôsobí. Na základe výsledkov v 330 vzorkách, ktoré boli tvorené kombináciou regiónov a odvetvím, sme mohli potvrdiť rozličnú významnosť vplyvu

jednotlivých parametrov. Takáto klasifikácia hrubého spreadu potvrdila výsledky z predchádzajúcich častí a aj predošlých výskumov. Okrem základných parametrov boli takýmto spôsobom identifikované aj parametre, ktoré priamo menujú konkrétnych upisovateľov, syndikát upisovateľov alebo reputáciu upisovateľa. Dôležitým výsledkom výskumu bol v rámci vytvorených 330 modelov častý výskyt parametrov akými sú miera preupísanosti a početnosť vzťahov ako významných pre určovanie hodnoty hrubého spreadu pre emisie z daného regiónu a z daného odvetvia.

Následne sme vo výskumnej časti práce testovali vzťah medzi hrubým spreadom a mierou preupísanosti a takisto klasifikáciu miery preupísanosti emisie. V tejto časti sme zaznamenali výsledky, ktoré nám umožnili potvrdiť, že vyššia miera preupísanosti je sprevádzaná aj s vyšším hrubým spreadom. Najvyššia miera preupísanosti bola pozorovaná pri emisiách v nižších objemoch. Pri klasifikácii miery preupísanosti bolo pozorované, že najviac preupísané emisie sú tie, kde emitent prichádza na trh ako prvoemitent, alebo sa na trhu vyskytuje najviac trikrát do roka. V prípade emitentov, ktorí prichádzali na trh viac ako trikrát sme mohli pozorovať významne nižšiu mieru preupísanosti. V tomto prípade sme mohli konštatovať, že tento jav môže mať dve vysvetlenia. Prvým vysvetlením bola skutočnosť, že emitent nie je tak známy a upisovateľ nedokáže správne oceniť emisiu, v takom prípade sme mohli prijať hypotézu certifikácie, ktorú sme vysvetlili v teoretickej časti práce. Druhým vysvetlením môže byť (úmyselné) podhodnotenie a z toho vyplývajúca preupísanosť, s cieľom upisovateľa (v spolupráci s emitentom) vytvoriť dopyt medzi investormi, nakoľko teoretické východiská uvádzajú, že umiestnenie nového emitenta medzi investorov prinášajú upisovateľovi zvýšené náklady. V tomto prípade bolo možné prijať hypotézu konfliktu záujmov a vytváranie tzv. informačnej asymetrie, čo môže naznačovať nekalé praktiky a porušenie pravidiel voľného trhu.

V časti rozboru výsledkov práce sme sformulovali pravidlá a odporúčania pre prax, ktoré vychádzali z výsledkov klasifikácie hrubého spreadu. Pri formulovaní pravidiel sme sa sústredili na región Európy a dosiahnutie, čo najnižšej kategórie výšky hrubého spreadu pre emitenta. Následne sme zhrnuli vedecké prínosy dizertačnej práce a navrhli sme ďalšie smerovanie výskumu v predmetnej oblasti výskumu.

Bibliografické zdroje

1. **ABIDI, N., FALAGIARDA, M., MIQUEL-FLORES, I. 2019.** Credit rating dynamics: evidence from a natural experiment. European Central Bank- Working Paper Series No 2274, April 2019.
2. **AGGARWAL, R., PRABHALA, N., R., PURI, M. 2002.** Institutional Allocation in Initial Public Offerings: Empirical Evidence. *In Journal of Finance*, Vol, 57, Issue 3, s. 1421 – 1442
3. **AKERLOF, G., A, 1970.** The Market for “Lemons”: Quality Uncertainty and the Market Mechanism. *In The Quarterly Journal of Economics*. Volume 84, Issue 3, August 1970, s. 488–500
4. **ALTINKLIÇ, O., HANSEN, R., S. 2000.** Are there economies of scale in underwriting fees? Evidence of rising external financing costs. *Review of Financial Studies*, 13(1), s. 191-218.
5. **ALTINKLIÇ, O., HANSEN, R., S. 2003.** Discounting and underpricing in seasoned equity offers. *In Journal of Financial Economics*, Volume 69, Issue 2, s. 285-323.
6. **ANDRES, Ch., BETZER, A., LIMBACH, P. 2014.** Underwriter reputation and the quality of certification: Evidence from high-yield bonds. *In Journal of Banking & Finance*, 2014, 40: s. 97-115.
7. **ARORA, N., SINGH, B.. 2020.** Do prestigious underwriters shape the performance of SME IPOs in India?. *In Global Business Review*, 2020, 0972150920963216.
8. **BAJO, E., CHEMMANUR, T., J., SIMONYAN, K., TEHRANIAN, H. 2016.** Underwriter networks, investor attention, and initial public offerings. *In Journal of Financial Economics*, Volume 122, Issue 2, November 2016, s. 376-408.
9. **BARON, D. 1982.** A Model of the Demand of Investment Banking Advising and Distribution Services for New Issues. *In Journal of Finance*, Vol. 37, Issue 4, s. 955 – 976.
10. **BEATTY, R., P., RITTER, J., R. 1986.** Investment banking, reputation, and the underpricing of initial public offerings. *In Journal of Financial Economics*, 15(1-2), s. 213–232.
11. **BERGER, A.N., ROMAN, R.A., 2015.** Did TARP banks get competitive advantages? *In Journal of Finance Quantitative Analysis*, 50 (6), s. 1199–1236.

12. **BESSEMBINDER, Hendrik, a kol. 2020.** Syndicate structure, primary allocations, and secondary market outcomes in corporate bond offerings. SMU Cox School of Business Research Paper No. 20, 2020, 4.
13. **BHARATH, S., DAHIYA, S., SAUNDERS, A., SRINIVASAN, A. 2007.** So what do I get? The bank's view of lending relationships. *In Journal of Financial Economics*, Volume 85, Issue 2, s. 368-419.
14. **BLACK, L.K., HAZELWOOD, L., N. 2013.** The effect of TARP on bank risk-taking. *In Journal of Financial Stability*, 9 (4), s. 790–803.
15. **BODIE, Z., KANE, A., ALAN, M. J. 2017.** Investments (11 ed.). McGraw Hill. 1040 s. ISBN 9781259277177.
16. **BOEHMER, B., BOEHMER, E., FISHE, R., P., H. 2006.** Do Institutions Receive Favorable Allocations in Ipos With Better Long Run Returns? *In Journal of Financial and Quantitative Analysis*, Vol. 41, s. 809-828, 2006.
17. **BOLTON, P., FREIXAS, X., SHAPIRO, J. 2012.** The Credit Ratings Game. *In The Journal of Finance*, (2012) Vol. LXVII, No. 1, February 2012.
18. **BONGAERTS, D., CREMERS, K., J., GOETZMANN, W., N. 2012.** „Tiebreaker: Certification and multiple credit ratings“. *In Journal of Finance*, (2012) vol. 67, no 1, s. 113-152.
19. **BOOTH, J., R., SMITH, R., L. 1986.** Capital raising, underwriting and the certification hypothesis. *In Journal of Financial Economics*, Vol. 15, s. 261–281.
20. **BOUWENS, J., DE KOK, T., VERRIEST, A. 2019.** The prevalence and validity of EBITDA as a performance measure. *Comptabilité-Contrôle-Audit*, 2019, 25.1: 55-105.
21. **BISSOONDOYALI-BHEENICK, E. 2005.** An analysis of the determinants of sovereign ratings. *In Global Finance Journal*, 15(3), s. 251–280.
22. **BRATISLAVSKÁ BURZA CENNÝCH PAPIEROV. 2023. ROČENKA 2022.** [Online] 04. 2023. [Dátum: 21. 05 2023.] <https://www.bsse.sk/bcpb/wp-content/uploads/2023/04/Rocenka-BCPB-2022.pdf>
23. **BROWNLEE, Jason. 2016.** XGBoost With python: Gradient boosted trees with XGBoost and scikit-learn. *Machine Learning Mastery*, 118 s.
24. **BURCH, T., R., NANDA, V., WARTHER, V. 2005.** Does it pay to be loyal? An empirical analysis of underwriting relationships and fees. *In Journal of Financial Economics*, Volume 77, s. 673–699.

25. **CALDERON, C., SCHAECK, K. 2016.** The effects of government interventions in the financial sector on banking competition and the evolution of zombie banks. *In Journal of Finance Quantitative Analysis* 51 (4), s. 1391–1436.
26. **CAMPBELL, T., S., KRACAW, W. 1980.** Information Production, Market Signaling, and the Theory of Financial Intermediation. *In Journal of Finance*, 35 (4), s. 863 – 882
27. **CARBO-VALVERDE, S., CUADROS-SOLAS, P., J., RODRIGUÉZ-FERNÁNDEZ, F. 2017.** Do banks and industrial companies have equal access to reputable underwriters in debt markets? *In Journal of Corporate Finance*, Volume 45, August 2017, s. 176-202.
28. **CARBO-VALVERDE, S., CUADROS-SOLAS, P., J., RODRIGUÉZ-FERNÁNDEZ, F. 2017.** Do banks and industrial companies have equal access to reputable underwriters in debt markets? *In Journal of Corporate Finance*, Volume 45, August 2017, s. 176-202.
29. **CARBO-VALVERDE, S., RODRIGUEZ-FERNANDEZ, F., SAUNDERS, A. 2021.** Underwriting bank bonds: Information sharing, certification and distribution networks. *In Journal of Corporate Finance*, 2021, 70: 102057.
30. **CARTER, R., MANASTER, S. 1990.** Initial public offerings and underwriter reputation. *In Journal of Finance*, 45(4), s. 1045–1067.
31. **CARTER, R., B., DARK, F., H. 1992.** An empirical examination of investment banking reputation measures. *In The Financial Review*, Vol. 27, Issue 3, s. 355-374.
32. **CHEN, T., GUESTRIN, C. 2016.** Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*. 2016, s. 785-794.
33. **CHEMMANUR, T., J., FULGHIERI, P. 1994.** Investment Bank Reputation, Information Production, and Financial Intermediation. *In Journal of Finance*, 49 (1), s. 57 – 19.
34. **CHEMMANUR, T., J., KRISHNAN, K. 2012.** Heterogeneous beliefs, IPO valuation, and the economic role of the underwriter in IPOs. *In Financial Management*, Volume 41, Issue 4, s. 769-811.
35. **CHEN, Ch., ZHAO, Y., ZHAO, Y. 2019.** Corporate bond ratings, underwriters' reputation and cost of bonds. *In Asia-Pacific Journal of Accounting & Economics*, 2019, 26.1-2: s. 1-16.

36. **CHEN, Z., WANG, Z. 2021.** Do firms obtain multiple ratings to hedge against downgrade risk? In *Journal of Banking and Finance*, 2021,123, 106006.
37. **CLARK, B., S. 2016.** Political economy: a comparative approach. Tretie vydanie. Santa Barbara, California: Praeger, 2016. 377 s. ISBN 9781440843266.
38. **COOK, E., F., GOLDMAN, L. 1988.** Asymmetric stratification. An outline for an efficient method for controlling confounding in cohort studies. In *American Journal of Epidemiology*, 1988, Issue 127, s. 626-639.
39. **CORWIN, S., A., SCHULTZ, P. 2005.** The role of IPO underwriting syndicates: Pricing, information production, and underwriter competition. In *The Journal of Finance*, Vol. 60, s. 443–486.
40. **DAMODARAN, A. 2011.** A Little Book of Valuation. 1. vydanie. New Jersey: John Wiley and Sons, 2011. 256 s. ISBN 978-1-118-00477-7
41. **DAŇO, F. 2021.** Záverečné práce. *Interná smernica č. 8/2021 o záverečných, rigorózných a habilitačných prácach*. [Online] 24. 11 2021. [Dátum: 21. 05 2023.] https://euba.sk/www_write/files/SK/docs/interne-smernice/2021/is_8_2021.pdf.
42. **DATTA, S. ISKANDAR-DATTA M., PATEL, A. 1997.** The Pricing of Initial Public Offers of Corporate Straight Debt. In *the Journal of Finance*, No. 52, s. 379 -396.
43. **DÍAZ-PÉREZ, F., M., BETHENCOURT-CEJAS, M. 2016.** CHAID algorithm as an appropriate analytical method for tourism market segmentation. In *Journal of Destination Marketing & Management*, 2016, 5.3: 275-282
44. **DICK-NIELSEN, J., NIELSEN, M., VON RÜDEN, L. 2021.** The value of bond underwriter relationships. In *Journal of Corporate Finance*, 2021, 68: 101930.
45. **DING, Y., ZHANG, H., ZHANG, J. 2007.** Private vs state ownership and earnings management: Evidence from Chinese listed companies. Corporate Governance. In *An International Review*, Vol. 15, s. 223–238.
46. **DUDA, R., O., HART, P., E., STORK, D., G. 2000.** Pattern classification. 2nd edition. New York: John Wiley and Sons, 2000, 688 s. ISBN 978-0-471-05669-0
47. **DUNBAR, C., G. 2000.** Factors affecting investment bank initial public offering market share. In *Journal of Financial Economics*, Vol. 55 (1), s. 3–41.
48. **EURÓPSKA KOMISIA. 2021.** Corporate bonds. [Dátum: 21. 05 2022.] Dostupné online: http://ec.europa.eu/info/business-economy-euro/banking-and-finance/financial-markets/corporate-bonds_cs

49. **ESMA. 2011.** Guidelines and Recommendations. Cooperation including delegation between ESMA, the competent authorities and the sectoral competent authorities under Regulation (EU) No 513/2011 on credit rating agencies .[Online] 10.1.2012 [Dátum: 21. 1. 2022.] <https://www.esma.europa.eu/sites/default/files/library/2015/11/2011-188.pdf>
50. **FABOZZI, F., ANSON, M., J., P., A. 2007.** Fixed Income Analysis. 2. vydanie, Hoboken, New Jersey: Willey, 2007, 733 s. ISBN 9780470069196
51. **FABOZZI, Frank J.; FABOZZI, Francesco A. 2021.** Bond markets, analysis, and strategies. MIT Press, 2021, 906 s, ISBN 026204627X.
52. **FANG, L., H. 2005.** Investment bank reputation and the price and quality of underwriting services. *In The Journal of Finance*, 2005, 60.6: 2729-2761.
53. **FERGUSON, N. 2011.** Vzostup peňazí: finančné dejiny sveta. Bratislava: Kaligram, 2011. 496 s. ISBN 978-80-8101-456-7
54. **FERNANDO, C., S., GATCHEV, V., A., SPINDT, P., A. 2005.** Wanna dance? How firms and underwriters choose each other. *In The Journal of Finance*, Volume 60, Issue 5, s. 2437-2469.
55. **FERNANDO, J. 2021.** Initial Public Offering (IPO). [Dátum: 01. 03 2022.] Dostupné online: <http://www.investopedia.com/terms/i/ipo.asp>
56. **FISCH, CH. 2019.** Initial coin offerings (ICOs) to finance new ventures. *In Journal of Business Venturing*, Volume 34, Issue 1, January 2019, s. 1-22.
57. **FULLER, M., A., SERVA, M., A., BENAMATI, J. 2007.** Seeing Is Believing: The Transitory Influence of Reputation Information on E-Commerce Trust and Decision Making. *In Decision Sciences*, Vol. 38, Issue 4, 2007, s. 675 – 699.
58. **GANDE, A., PURI, M., SAUNDERS, A. 1999.** Bank entry, competition, and the market for corporate bond underwriting. *In Journal of Financial Economics* 54, s. 165–195.
59. **GANDE, A., PURI, M., SAUNDERS, A WALTER, I. 1997.** Bank underwriting of debt securities: Modern evidence. *In The Review of Financial Studies* 10, s. 1175–1202.
60. **GEPP, A., KUMAR, K. 2015.** Predicting financial distress: A comparison of survival analysis and decision tree techniques. *In Procedia Computer Science*, 2015, 54: s. 396-404.
61. **GOLDSTEIN, M., UCHIDA, S. 2016.** A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data, *In PLoS One* 11 (2016)e0152173.

62. **GRIFFIN, J., M., HARRIS, J., H., TOPALOGLU, S. 2007.** Why are IPO investors net buyers through lead underwriters? In *Journal of Financial Economics* 85 (2007) s. 518–551.
63. **GUPTA, B., a kol. 2017.** Analysis of various decision tree algorithms for classification in data mining. In *International Journal of Computer Applications*, 2017, 163.8: s. 15-19.
64. **HAKENES, H., SCHNABEL, I., 2010.** Banks without parachutes: competitive effects of government bail-out policies. In *Journal of Financial Stability* 6 (3), 156–168.
65. **HALE, G., SANTOS, J., A., C. 2006.** Evidence on the costs and benefits of bond, IPOs. Working Paper Series 2006-42, Federal Reserve Bank of San Francisco.
66. **HANLEY, K., W. 1993.** Underpricing of Initial Public Offerings and the Partial Adjustment Phenomenon. In *Journal of Financial Economics*, Vol. 34, Issue 2, s. 231-250.
67. **HANLEY, K., W., HOBERG, G. 2010.** The information content of IPO prospectuses. In *Review of Financial Studies*, Vol. 23, s. 2821–2864.
68. **HARVEY, C., R., GIAMBONA, E., GRAHAM, J., R., BODNAR, G., M. 2018.** The Theory and Practice of Corporate Risk Management: Evidence from the Field. In *Financial Management*, Vol. 47, Issue 4, Winter 2018, s. 783 – 832.
69. **HEARN, B. 2014.** The impact of institutions, ownership structure, business angels, venture capital and lead managers on IPO firm underpricing across North Africa. In *Journal of Multinational Financial Management*, Vol. 24, February 2014, s. 19 – 24.
70. **HEELEY, M., B., MATUSIK, S., F., JAIN, N. 2007.** Innovation, appropriability, and the underpricing of initial public offerings. In *Academy of Management Journal*, 50(1), s. 209–225.
71. **HOMER, S., SYLLA, R. 2005.** A History of Interest Rates. 4th edition. Willey Fnance, August 2005. 736 s. ISBN: 978-0471732839.
72. **HOVAKIMIAN, A., OPLER, T., TITMAN, S. 2001.** The debt-equity choice: an analysis of issuing firms. In *Journal of Financial Quantitative Analysis*, Volume 36, s. 1–24.
73. **HU, X., SHI, J., WANG, L., YU, J. 2020.** Foreign Ownership in Chinese Credit Ratings Industry: Information Revelation or Certification? In *Journal of Banking & Finance*, (2020) 105891.
74. **HU, Y., et al. 2021.** Underwriter reputation and IPO underpricing: The role of institutional investors in the Chinese growth enterprise market. In *International Review of Financial Analysis*, 2021, 78: 101956.

75. **HU, Y., RITTER, J. 2007.** Multiple bookrunners in IPOs. University of Florida, Working Paper.
76. **HUNT, C., REID, G., ROSBOROUGH, L. 2015.** A primer on New Zealand's capital markets. Reserve Bank of New Zealand Bulletin, vol. 78, no. 3, May 2015. [Dátum: 21. 03 2022.] Dostupné online: <http://www.rbnz.govt.nz/-/media/reservebank/files/publications/bulletins/2015/2015may78-3.pdf>
77. **HUBER, P., J. 1973.** Robust regression: asymptotics, conjectures and Monte Carlo. *In The annals of statistics*, 1973, s. 799-821.
78. **HUTCHESON, G. 2011.** GLM models and OLS regression. *In L. Moutinho and G. D. Hutcheson, The SAGE Dictionary of Quantitative Management Research*, s. 224-228.
79. **HUYGHEBAERT, N., XU, W. 2015.** What determines the market share of investment banks in Chinese domestic IPOs? *In China Economic Review*, Volume 34, July 2015, s. 150-168.
80. **IBM. 2022.** IBM Documentation: Cloud Pak for Data 4.0. Modelling for CHAID Node. [Dátum: 07. 04 2022.] Dostupné online: <http://www.ibm.com/docs/en/cloud-paks/cp-data/4.0?topic=modeling-chaid-node>
81. **IBM SPSS MODELER. 2021.** IBM SPSS Modeler 18.3 Algorithms Guide Documentation. [Dátum: 07. 04 2022.] Dostupné online: http://www.ibm.com/docs/en/SS3RA7_18.3.0/pdf/AlgorithmsGuide.pdf
82. **INTERNATIONAL RISK MANAGEMENT INSTITUTE. 2021.** Financial Institution Bonds: Glossary. [Dátum: 21. 05. 2022.] Dostupné online: <http://www.irmi.com/term/insurance-definitions/financial-institution-bond> [citované dňa: 27.11.2021]
83. **JAIN, B., A., JAYARAMAN, N., KINI, O., 2008.** The path-to-profitability of Internet IPO firms. *In Journal of Business Venturing*, 23(2), s. 165–194.
84. **JAGANNATHAN, R., SHERMAN, A. E. 2006.** Why do IPO auctions fail? *In NBER Working Paper Series*, 12151, 2006, National Bureau of Economic Research.
85. **JENKINSON, T., LJUNGQVIST, A. 2001.** Going Public: the Theory and Evidence on How Companies Raise Equity Finance. Oxford University Press, Oxford. ISBN 978-0198295990
86. **JEON, J., Q., LEE, C., NASSER, T., VIA, M., T. 2015.** Multiple lead underwriter IPOs and firm visibility. *In Journal of Corporate Finance*, Vol. 32, s. 128–149.
87. **JOHNSON, J. M., MILLER, R. E. 1988.** Investment banker prestige and the underpricing of initial public offerings. *In Financial Management*, 17(2), s. 19-29.

88. **KAO, J., L., WU, D., YANG, Z. 2007.** Regulations, earnings management, and post-IPO performance: The Chinese evidence. *In Journal of Banking & Finance*, Vol. 33, s. 63–76.
89. **KASS, G., V. 1980.** An exploratory technique for investigating large quantities of categorical data. *In Journal of The Royal Statistical Society Series C-applied Statistics*, Issue 29, June 1980, s. 119–127.
90. **KATTI, S., PHANI, B., V. 2016.** Underpricing of Initial Public Offerings: A Literature Review. *In Universal Journal of Accounting and Finance*, 4(2), s. 35 - 52.
91. **KRAFT, P. 2015.** Do rating agencies cater? Evidence from rating-based contracts. *In Journal of Accounting and Economics*, No 59(2), s. 264-283.
92. **KREBBERS, A., a kol. 2023.** Orderbook demand for corporate bonds. *In European Financial Management*, 2023, 29.1: s. 247-287.
93. **LILLIEFORS, H., W. 1967.** On the Kolmogorov-Smirnov test for normality with mean and variance unknown. *In Journal of the American Statistical Association*, 1967, 62.318: s. 399-402.
94. **KENT STATE UNIVERSITY LIBRARIES. 2017.** SPSS tutorials: CHI-SQUARE TEST OF INDEPENDENCE. [Dátum: 07. 04 2022.] Dostupné online: <http://libguides.library.kent.edu/spss/chisquare>
95. **KRIGMAN, L., SHAW, W., H., WOMACK, K. 1999.** The persistence of IPO mispricing and the predictive power of flipping. *In Journal of Finance*, Vol.54, Issue 3, s. 1015-1044, 1999.
96. **KRIGMAN, L., SHAW, W., H., WOMACK, K. 2001.** Why do firms switch underwriters? *In Journal of Financial Economics*, Vol. 60, Issue 2-3, s. 245-284. Dostupné online: [http://doi.org/10.1016/S0304-405X\(01\)00045-9](http://doi.org/10.1016/S0304-405X(01)00045-9)
97. **KRUEGER, A., O. 1974.** The Political Economy of the Rent-Seeking Society. *In American Economic Review*, 1974, vol. 64, issue 3, s. 291-303.
98. **KUHN, M. a kol. 2013.** Applied predictive modeling. New York: Springer, 2013. ISBN 978-1-4614-6848-6.
99. **LEE, J. 2010.** President Obama Signs Wall Street Reform: "No Easy Task". The White House President Barack Obama. Dostupné online [Dátum: 19. 01. 2022.]: <https://obamawhitehouse.archives.gov/blog/2010/07/21/president-obama-signs-wall-street-reform-no-easy-task>
100. **LELAND, H., E., PYLE, D., H. 1977.** Informational Asymmetries, Financial Structure, and Financial Intermediation. *In Journal of Finance*, 32 (2), s. 371 – 387.

- 101. LEVICK, E., YANG, S. 2017.** Composition of Supranational, Sovereign, and Agency Bonds in Australia. Education: Fixed Income 101. S&P Dow Jones Indices LLC, January 2017. [Datum: 16. 03. 2022.] Dostupné online: <http://www.spglobal.com/spdji/en/documents/education/education-composition-of-supranational-sovereign-and-agency-bonds-in-australia.pdf>
- 102. LEVOW. 2004.** Corporate Operational Underwriting process. Business Practices. Dostupné online: [Datum: 16. 01. 2022.] <http://www.levow.com/wp-content/uploads/SG/-%20Debt%20Capital%20Markets/Corporate%20Bond%20Underwriting%20Process>.
- 103. LIU, X., RITTER, J., R. 2011.** Local Underwriteroligopoles and IPO underpricing. In *Journal of Financial Economics*, Vol. 102, Issue 3, December 2011, s. 579 – 601.
- 104. LIU, X., SHERMAN, E., ZHANG, Y. 2014** The long-run role of the media: Evidence from initial public offerings. In *Management Science*, 2014, 60.8: s. 1945-1964.
- 105. LIVINGSTON, M., MILLER, R., E. 2000.** Investment Bank Reputation and the Underwriting of Nonconvertible Debt. In *Financial Management*, 29(2), s. 21–34.
- 106. LOH, W.-Y. 2014.** Fifty Years of Classification and Regression Trees. In *International Statistical Review*, Volume 82, Issue 3, s. 329–348.
- 107. LOU, Y., VASVARI, F., P. 2011.** The Role of Reputable Auditors and Underwriters in the Design of Bond Contracts. In *Journal of Accounting, Auditing & Finance*. 2013; 28(1): s. 20-52.
- 108. LOUGHAN, T., RITTER, J. R. 2002.** Why do not issuers get upset about leaving money on the table in IPOs? In *The Review of Financial Studies*, 15 (2), s. 413 – 444.
- 109. LOWRY, M., SCHWERT, G. W. 2004.** Is the IPO pricing process efficient? In *Journal of Financial Economics*, 71 (1), s. 3 – 26.
- 110. MA, B., WANG, Y., LI, Z. 2021.** Application of data mining in Basketball statistics. In *Applied Mathematics and Nonlinear Sciences*, s 1 - 10.
- 111. MAHATIDANA, M., R., A., YUNITA, I. 2017.** An Examination Factors Influencing Underpricing of IPOs in Financial and Manufacturing Industries on The Indonesia Stock Exchange over The Period of 2011-2016. In *International Journal of Scientific and Research Publications*, Vol. 7, Issue 11, November 2017, s. 457 – 465.
- 112. MATHIS, J., MCANDREWS, J., ROCHET, J.-C. 2009.** Rating the raters: Are reputation concerns powerful enough to discipline rating agencies? In *Journal of Monetary Economics*, 56(5), s. 657–674.
- 113. MILANOVIĆ, M., STAMENKOVIĆ, M. 2016.** CHAID decision tree: Methodological frame and application. In *Economic Themes*, 2016, 54.4: 563-586.

114. MITCHELL, T., M. 1997. Does machine learning really work?. In *AI magazine*, 1997, Volume 18, Issue 3, 11 s.
115. MOODYS. **Rating Symbols and Definitions. 2021.** [Dátum: 16. 01. 2022.]
Dostupné online:
http://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_79004
116. MOREIRA, J., CARVALHO, A., HORVATH, T. 2018. A general introduction to data analytics. John Wiley & Sons, 2018. 352 s. ISBN 978-1-119-29626-3.
117. MORRICONE, S., MUNARI, F., ORIANI, R., de RASSENFOSSE, G. 2017. Commercialization Strategy and IPO Underpricing. Working Papers 4, Chair of Innovation and IP Policy.
118. NAEEM, M., A. et al. 2021. Comparative efficiency of green and conventional bonds pre-and during COVID-19: An asymmetric multifractal detrended fluctuation analysis. In *Energy Policy*, 2021, 153: 112285.
119. NAGLER, F., OTTONELLO, G. 2021. Inventory-Constrained Underwriters and Corporate Bond Offerings. In BAFFI CAREFIN Centre Research Paper, No. 2017-48.
120. NARAYANAN, R., P., RANGAN, K., P., RANGAN, N., K. 2007. The effect of private-debt-underwriting reputation on bank public-debt underwriting. In *Review of Financial Studies*, Volume 20, Issue 3, s. 597-618.
121. NGUYEN-SY, Tuan, a kol. 2020. Predicting the compressive strength of concrete from its compositions and age using the extreme gradient boosting method. *Construction and Building Materials*, 2020, 260: 119757.
122. NIKOLOVA, S., WANG, L., WU, J. 2020. Institutional allocations in the primary market for corporate bonds. In *Journal of Financial Economics*, 137 (2020) s. 470-490.
123. O'MALLEY, Ch. 2015. Bonds Without Borders: A History of the Eurobond Market. United Kingdom: Wiley, 2015. 288 s. ISBN 978-1118843888
124. OPLER, T., C., SARON, M., TITMAN, S. 1997. Designing capital structure to create shareholder value. In *Applied Corporate Finance*, Vol. 64, s. 21–32.
125. OSMAN, Ahmedbahaaaldin Ibrahim Ahmed, a kol. 2021. Extreme gradient boosting (Xgboost) model to predict the groundwater levels in Selangor Malaysia. In *Ain Shams Engineering Journal*, 2021, 12.2: s. 1545-1556.
126. OTTONELLO, G. RIZZO, A., E., ZAMBRANA, R. 2022. Bank Trading Networks and Access to the Corporate Bond Market. Available at SSRN 4287217, 2022.

127. **PANDYA, Rutvija, PANDYA, Jayati. 2015.** C5. 0 algorithm to improved decision tree with feature selection and reduced error pruning. *In International Journal of Computer Applications*, 2015, 117.16: s. 18-21.
128. **PAPAIOANOU, G., J., KARAGOZOGLU, A., K. 2017.** Underwriter Services and the New Issue Market. Elsevier, 2017. ISBN: 978-0-12-803282-4.
129. **PEDREGOSA, F., et al. 2011.** Scikit-learn: Machine learning in Python. *In the Journal of machine Learning research*, 12: s. 2825-2830.
130. **PENG, J., BRUCATO, P., F. 2004.** An empirical analysis of market and institutional mechanisms for alleviating information asymmetry in the municipal bond market. *In Journal of Economics and Finance*, Volume 28, s. 226–238 (2004).
131. **PENG, J., LI, Q., LI, H., LIU, L., YAN, Z., ZHANG, S. 2018.** Fraud detection of medical insurance employing outlier analysis, in: 2018 IEEE 22nd International Conference on Computer Supported Cooperative Work in Design (CSCWD), IEEE, 2018, s. 341–346.
132. **PERTAIA, G., PROKHOROV, A., URYASEV, S. 2021.** A new approach to credit ratings. *In Journal of Banking & Finance*, (2021) 106097.
133. **PUGA, D., TREFLT, D. 2012.** International Trade and Institutional change: medieval venices response to globalization. Working paper series: National Bureau of Economic Research, August 2012.
134. **PREMTI, A., MADURA, J. 2013.** Motives and consequences of IPOs in cold periods. *In The Quarterly Review of Economics and Finance*, 53(4), s. 486–496.
135. **PURI, M. 1996.** Commercial banks in investment banking: Conflict of interest or certification role? *In Journal of Financial Economics* 40, s. 373–401.
136. **PURI, M. 1999.** Commercial banks as underwriters: Implications for the going public process. *In Journal of Financial Economics*, Volume 54, Issue 2, s. 133-163. Dostupné online: [http://doi.org/10.1016/S0304-405X\(99\)00034-3](http://doi.org/10.1016/S0304-405X(99)00034-3)
137. **PWC. 2017.** Roadmap for an IPO: A Guide To Going Public. A publication from PwC Deals, November 2017. [Dátum: 27. 01. 2022.] Dostupné online: http://www.pwc.com/hu/hu/szolgaltatasok/konyvvizsgalat/szamviteli-tanacsadas/kiadvanyok/roadmap_for_an_ipo.pdf
138. **RAU, P. R. 2000.** Investment bank market share , contingent fee payments , and the performance of acquiring firms. *In Journal of Financial Economics*, 56, s. 293–324.

- 139. REVATHY, R., LAWRENCE, R. 2017.** Comparative analysis of C4. 5 and C5. 0 algorithms on crop pest data. *In International Journal of Innovative Research of Computer and Communication Engineering*, 2017, 5.1: s. 50-58.
- 140. RICHTER, S., et al. 2021.** Determinants of project bond prices—Insights into infrastructure and energy capital markets. *In Energy Economics*, 2021, 97: 105175
- 141. RITTER, J., R., WELCH, I. 2002.** A review of IPO activity, pricing, and allocations. *In Journal of Finance*, Vol.57, s. 1795 – 1828, 2002.
- 142. ROCK, K. 1986.** Why new issues are underpriced. *In Journal of Financial Economics*, Vol. 15, Issue 1-2, s. 187-212.
- 143. SANGIAGRI, F., SPATT, C. 2017.** The economics of credit rating agencies. *In Found. Trend. Finance*, 12 (1), s. 1–116.
- 144. SCHENONE, C. 2004.** The effect of banking relationships on the firm's IPO underpricing. *In The Journal of Finance*, Volume 59, Issue 6, s. 2903-2958.
- 145. SEC. 2021.** What are Corporate Bonds? Investor Bulletin. Office of Investor Education and Advocacy. [Dátum: 03. 02. 2022.] Dostupné online: http://www.sec.gov/files/ib_corporatebonds.pdf
- 146. SHERMAN, A., E. 1999.** Underwriter certification and the Effect of Shelf Registration on Due Dilligence. *In Financial Management*, 28 (1), s. 5 – 19.
- 147. SIANI, K. 2019.** Global demand spillovers in corporate bond issuance: The effect of underwriter networks. Available at SSRN, 2019.
- 148. SIDDHARTHA, J. 2011.** Interest Rate Markets : A Practical Approach to Fixed Income. 1st edition. New York: John Willey & Sons, 2011. 368 s. ISBN: 9780470932209
- 149. SMALE, W. 2016.** What are credit agencies? [Dátum: 06. 03 2022.] Dostupné online: <http://www.bbc.com/news/business-36629099>
- 150. SOLLNER, M., LEIMEISTER, J., M. 2013.** What we really know about antecedents of trust: a critical review of the empirical information systems literature on trust. *In Psychology of Trust: New Research*. Nova Science Publishers, Hauppauge, New York, USA, 2013. s. 127-155. ISBN: 978-1-62808-552-5
- 151. SONG, Y., Y., LU, Y. 2015.** Decision tree methods: applications for clasification and prediction. *In Shanghai Archives of Psychiatry*, Volume 27, Issue 2, s. 130 – 135.
- 152. TAN, P., STEINBACH, M., KUMAR, V. 2006.** Introduction to Data Mining. 1.vydanie. New York: Addison-Wesley, 2006. 792 s. ISBN 978-0321321367

153. **TANG, T., T. 2009.** Information asymmetry and firms' credit market access: Evidence from moody's credit rating format refinement. *In Journal of Finance Economics*, 93 (2), s. 325–351.
154. **TEJA, A. 2021.** A Comparison of Underwriter Reputation Measurement Methods In Explaining IPO Stock Performance. *Akurasi: Journal of Accounting and Finance Studies*, 2021, 4.2: s. 195-209.
155. **THAKUR, M. 2020.** Bond Rating. Fixed Income Resources. WallStreetMojo, [Dátum: 27. 02. 2022.] Dostupné online: <http://www.wallstreetmojo.com/bond-rating/>
156. **THAU, A. 2010.** The Bond Book. Tretie vydanie. New York: McGraw-Hill Education, 2010. 448 s. ISBN 978-0071664707
157. **TOBIN, J., GOLUB, S. 1997.** Money, Credit and Capital. McGraw-Hill Education. 384 s. ISBN 978-0070653368.
158. **TUERLINCKX, F., RIJMEN, F., MOLENBERGHS, G., VERBEKE, G., BRIGGS, VAN DEN NOORTGATE, D., W., MEULDERS, W., DE BOECK, P. 2004.** Estimation and Software. In: Explanatory Item Response Models: A Generalized Linear and Nonlinear Approach, P. De Boeck, and M. Wilson, eds. New York: Springer-Verlag, s. 343–373.
159. **TUHKANEN, H., VULTURIUS, G. 2022.** Are green bonds funding the transition? Investigating the link between companies' climate targets and green debt financing. *In Journal of Sustainable Finance & Investment*, 2022, 12.4: s 1194-1216.
160. **TULLOCK, G. 2003.** The Origin Rent-Seeking Concept. *In International Journal of Business and Economics*, 2003, Vol. 2, No. 1, s. 1-8.
161. **TURRENT, G., C., B., ARIZA, L., R. 2016.** Corporate governance ratings on listed companies: An institutional perspective in Latin America. *In European Journal of Management and Business Economics*, 25 (2016) s. 63–75.
162. **TVARDZIK, J. 2021.** Prečo burza vo Varšave i Prahe oživa, ale bratislavská umiera? [Dátum: 21. 12. 2021.] Dostupné online: <https://index.sme.sk/c/22579199/preco-burza-vo-varsave-i-prahe-oziva.html>
163. **QUINLAN, J., R. 2014.** C4. 5: Programs for Machine Learning. Elsevier. ISBN 9781558602380
164. **WANG, F., et al. 2022.** Effect of geographical distance between underwriters and listed companies on IPO underpricing: Evidence from China's A-share market. *In International Review of Economics & Finance*, 2022, 79: s. 340-352

165. **WELCH, I. 1989.** Seasoned offerings, imitation costs, and the underpricing of initial public offerings. *In The Journal of Finance*, Vol. 44, Issue 2, s. 421-449.
166. **WEST, J., BHATTACHARYA, M. 2016.** Intelligent financial fraud detection: A comprehensive review,. *In Computer Security*, vol. 57 (2016) 47–66.
167. **XU, S., GONG, G., GONG, X. 2017.** Accruals quality, underwriter reputation, and corporate bond underpricing: Evidence from China. *In China Journal of Accounting Research*, 2017, 10.4: s. 317-339.
168. **YAHYA, N., C., RASHID, R., M., RAHIM, R., A. 2019.** The Influence of Information Asymmetry on IPO Lock-up Provisions: Evidence from Malaysian Market. *In Global Business Review*, Vol. 20, Issue 3 (2019), s. 613 – 626.
169. **YASUDA, A. 2005.** Do Bank Relationships Affect the Firms Underwriter Chocie in the Corporate-Bond Underwriting Market? *In the Journal of Finance*, Vol. 9, No. 3, June 2005.
170. **YEOMAN, J., C. 2001.** The optimal spread and offering price for underwritten securities. *In Journal of Financial Economics*, Vol.62, s. 169-198, 2001.
171. **YUNG, Ch., ZENDER, J., F. 2010.** Moral hazard, asymmetric information and IPO lockups. *In Journal of Corporate Finance*, 16(3), s. 320–332.
172. **ZAVOLOKINA, L., SCHLEGEL, M., SCHWABE, G. 2021.** How can we reduce information asymmetries and enhance trust in ‘The Market for Lemons’? *In Information Systems and e-Business Management*, Volume 19 (2021), s. 883–908.
173. **Zákon č. 530/1990 Zb. o dlhopisoch**
174. **ZHANG, K., Q a kol. 2022.** Green finance, innovation and the energy-environment-climate nexus. *In Frontiers in Environmental Science*, 2022, 602.
175. **ZHOU, F., a kol. 2019.** Cascading logistic regression onto gradient boosted decision trees for forecasting and trading stock indices. *In Applied Soft Computing*, 2019, 84: 105747.

Zoznam príloh

<i>Príloha - ČASŤ A</i>	2
<i>Príloha - ČASŤ B</i>	4
<i>Príloha - ČASŤ C</i>	7
<i>Príloha - ČASŤ D</i>	19
<i>Príloha - ČASŤ E</i>	22
<i>Príloha – ČASŤ F</i>	26
<i>Príloha – ČASŤ G</i>	46
<i>Príloha – ČASŤ H</i>	48