



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV FINANCÍ

INSTITUTE OF FINANCES

MODELOVÁNÍ PREDIKCE ÚSPĚCHU HIGH-TECH STARTUPŮ V PODMÍNKÁCH EVROPSKÉ UNIE

MODELING THE PREDICTION OF THE SUCCESS OF HIGH-TECH STARTUPS IN THE CONDITIONS OF THE
EUROPEAN UNION

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. David Rýznar

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Michal Karas, Ph.D.

BRNO 2025

Zadání diplomové práce

Ústav:	Ústav financí
Student:	Bc. David Rýznar
Vedoucí práce:	doc. Ing. Michal Karas, Ph.D.
Akademický rok:	2024/25
Studijní program:	Účetnictví a finanční řízení podniku

Garantka studijního programu Vám v souladu se zákonem č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a se Studijním a zkušebním řádem VUT v Brně zadává diplomovou práci s názvem:

Modelování predikce úspěchu high-tech startupů v podmínkách Evropské unie

Charakteristika problematiky úkolu:

Vymezení cíle práce a metod
Teoretické vymezení úspěšnosti start-upů a možností predikce
Analýza relevantního odvětví
Popis analyzovaného vzorku a použitých metod
Vlastní návrh modelu predikce a jeho ověření
Závěr
Seznam použité literatury
Přílohy

Cíle, kterých má být dosaženo:

Cílem práce je odvodit a ověřit vlastní model predikování úspěšnosti start-upů a to na základě finančních a nefinančních ukazatelů.

Základní literární prameny:

COCKAYNE, Daniel. What is a startup firm? A methodological and epistemological investigation into research objects in economic geography. Geoforum, roč. 107 (2019), s. 77-87. ISSN 0016-7185

KIVILUOTO, Niklas. Growth as evidence of firm success: myth or reality? Entrepreneurship & Regional Development, roč. 25 (2013), č.7-8, s. 569-586. ISSN: 1464-5114

GOMPERS, Paul; KOVNER, Anna a LERNER, Josh. Specialization and Success: Evidence from Venture Capital. Journal of Economics & Management Strategy, roč. 18 (2009), s. 817-844. ISSN: 1530-9134

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2024/25

V Brně dne 9.2.2025

L. S.

prof. Ing. Mária Režňáková, CSc.
garantka

prof. Ing. et Ing. Stanislav Škapa, Ph.D.
děkan

Abstrakt

Tato diplomová práce je zaměřena na vytvoření predikčního modelu pro hodnocení úspěšnosti startupů v high-tech sektoru v zemích Evropské unie. V teoretické části je definován pojem startup, popsán jeho význam pro ekonomiku a identifikovány klíčové faktory ovlivňující jeho úspěšnost. V praktické části je nejprve vyjádřen vliv zkoumaných faktorů na úspěšnost a následně vytvořen a ověřen vlastní prediktivní model s přesností vyšší než 75 %.

Abstract

This thesis focuses on the development of a prediction model for evaluating the success of startups in the high-tech sector in the European Union countries. The theoretical part defines the concept of startup, describes its importance for the economy and identifies the key factors influencing its success. In the practical part, the influence of the investigated factors on the success rate is first expressed and then the actual predictive model is developed and validated with an accuracy of more than 75%.

Klíčová slova

startup, úspěšnost, high-tech, predikční model, logistická regrese

Keywords

startup, success, high-tech, prediction model, logistic regression

Bibliografická citace

RÝZNAR, David. *Modelování predikce úspěchu high-tech startupů v podmínkách Evropské unie* [online]. Brno, 2025 [cit. 2025-05-13]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/168488>. Diplomová práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav financí. Vedoucí práce doc. Ing. Michal Karas, Ph.D.

Čestné prohlášení

Prohlašuji, že předložená diplomová práce je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušil autorská práva (ve smyslu zákona č. 121/2000 Sb., o právu autorském a o právech souvisejících s právem autorským).

V Brně dne 13. 5. 2025

Bc. David Rýznar

autor

Poděkování

Děkuji panu doc. Ing. Michalu Karasovi, PhD. za odborné vedení mé diplomové práce a za jeho cenné rady a inspirující podněty, které mi při zpracovávání této práce poskytl.

OBSAH

ÚVOD.....	10
VYMEZENÍ CÍLE PRÁCE A METOD.....	12
1. Teoretické vymezení úspěšnosti startupu a možností predikce	13
1.1. Vymezení pojmu startup.....	13
1.2. Přínos startupů pro ekonomiku.....	14
1.3. High-tech startup.....	16
1.4. Vývoj high-tech sektoru.....	17
1.5. Vymezení úspěšnosti startupu	19
1.5.1. Možnosti predikce.....	20
1.5.2. Ziskovost jako metrika úspěšnosti.....	24
1.5.3. Definice úspěšnosti startupu pro model.....	26
1.6. Faktory ovlivňující úspěch startupů.....	27
2. Analýza high-tech odvětví.....	33
3. Popis analyzovaného vzorku a použitých metod.....	37
3.1. Analyzovaný vzorek	37
3.1.1. Kaplan-Meierova křivka dosahování zisku	38
3.2. Metodika predikce	40
4. Vlastní návrh modelu predikce a jeho ověření	46
4.1. Popisná statistika.....	47
4.2. Výsledky jednorozměrného testování vlivu prediktorů.....	49

4.3. Zhodnocení predikční síly a vlivu prediktorů na úspěch v jednorozměrném testování	59
4.4. Kontrola korelace.....	74
4.5. Výsledky vícerozměrného testování.....	75
4.5.1. Porovnání dat jednorozměrného a vícerozměrného testování	75
4.5.2. Stanovení významných prediktorů	76
4.5.3. Zhodnocení predikční síly modelu	78
4.5.4. Vyhodnocení stability modelu.....	79
4.5.5. Praktický příklad.....	80
ZÁVĚR	82
SEZNAM TABULEK:	88
SEZNAM GRAFŮ:	90

ÚVOD

Startupy jsou klíčovými aktéry v moderní ekonomice, jejichž význam stále roste. Jako mladé, inovativní společnosti představují motor technologického pokroku a ekonomického růstu, který často zásadně ovlivňuje celé sektory. Mnoho startupů čelí vysoké míře nejistoty, omezenému financování a intenzivní konkurenci, což vede k tomu, že značná část z nich nepřežije první roky své existence.

Předmětem této diplomové práce je analýza faktorů ovlivňujících úspěšnost high-tech startupů v zemích Evropské unie (EU27) a návrh predikčního modelu, který by umožnil identifikovat pravděpodobnost jejich úspěchu. High-tech sektor patří k nejrychleji rostoucím odvětvím s vysokým potenciálem pro inovace a tvorbu pracovních míst, proto je pochopení faktorů ovlivňujících jejich úspěch klíčové nejen pro investory a zakladatele.

První část práce se bude věnovat teoretickému vymezení úspěšnosti startupů a možnostem její predikce. Bude obsahovat definici pojmu startup, jeho význam pro ekonomiku a specifika high-tech startupů, která je budou odlišovat od jiných typů podniků. Dále se tato část zaměří na různé přístupy k měření úspěchu startupů. V textu budou také popsány hlavní faktory, které mohou ovlivnit úspěch startupů.

Druhá část práce se zaměří na analýzu relevantního high-tech odvětví, ve kterém vybrané startupy působí. Tento sektor bude definován svou vysokou technologickou náročností, rychlým tempem inovací a značným růstovým potenciálem. Součástí této části bude také zhodnocení podílu high-tech podniků na ekonomice.

Ve třetí části práce bude podrobně popsán analyzovaný vzorek startupů a metody, které budou použity k vytvoření predikčního modelu. Tato část bude zahrnovat popis sběru dat a jejich zpracování. Dále zde budou popsány a vysvětleny metody analyzování prediktorů a postupy v rámci jednorozměrného testování, kontroly korelace, vícerozměrného testování a ověření modelu.

V poslední části bude navržen a ověřen vlastní predikční model. Cílem závěrečné části bude identifikovat významné prediktory úspěchu a vytvořit statistický model, který bude schopen predikovat úspěšnost startupů na základě vybraných faktorů. Tato část bude také zahrnovat

praktickou aplikaci modelu na reálných datech a hodnocení predikční síly a stability tohoto modelu.

Výsledný predikční model dosáhl klasifikační přesnosti pro rozlišení mezi úspěšnými a neúspěšnými startupy, která přesahuje 75 % a to na základě dat z prvních čtyř let jejich existence. V první řadě však model dosáhl hodnoty AUC 0.8253, což znamená, že model má velmi dobrou diskriminační schopnost a je tedy vhodným nástrojem pro podporu investičního rozhodování a strategického řízení startupů.

VYMEZENÍ CÍLE PRÁCE A METOD

Cílem diplomové práce je odvodit a ověřit vlastní model predikce úspěšnosti startupů na základě finančních a nefinančních ukazatelů. Tento model má umožnit přesnější hodnocení pravděpodobnosti úspěchu startupů, což může být užitečné například pro investory nebo zakladatele firem. K dosažení tohoto hlavního cíle bude potřeba postupovat podle následujících dílčích cílů.

Pro dosažení cíle je nejdříve nutné definovat, co je to startup, jaké jsou jeho charakteristiky, co představuje úspěch startupu a jaké faktory tento úspěch ovlivňují. Dále je nutné vybrat odvětví, ze kterých budou vybrána relevantní data pro následnou analýzu. Dále definovat klíčové finanční a nefinanční ukazatele, které budou použity při tvorbě predikčního modelu.

V první části práce budou literární rešerši vymezeny pojmy startup a úspěšnost startupu. Cílem literární rešerše bude získat přehled o dosavadních poznatcích a teoriích v této oblasti, včetně definic, klíčových faktorů úspěchu a přístupů k měření úspěšnosti.

V další části práce bude využita sekundární analýza dat. Data budou sbírána konkrétně z databází Orbis Europe či Eurostat. Tato metoda představuje analýzu již existujících dat.

Další metodou je syntéza, která bude klíčová při sestavování vlastního predikčního modelu, kdy je nutné propojit poznatky z různých teoretických a empirických zdrojů a vytvořit ucelený model, který reflektuje specifika high-tech startupů.

Při analýze rozdílů mezi jednorozměrným a vícerozměrným testováním vlivu jednotlivých prediktorů na úspěch startupů bude využito srovnávání.

Při tvorbě predikčního modelu budou využity různé statistické postupy, jako jsou: logistická regrese, korelační analýza, metoda zpětné eliminace či metoda křížové validace. Tyto metody umožňují kvantitativně vyhodnotit vztahy mezi proměnnými a identifikovat faktory, které mají největší vliv na úspěšnost startupů.

1. Teoretické vymezení úspěšnosti startupu a možností predikce

1.1. Vymezení pojmu startup

Startup je fenomén, který nemá v literatuře jednoznačně vymezenou definici. Podle autora Cockayne (2019) z rozhovorů s respondenty v jeho výzkumu vyplynulo, že řada z nich neměla jasnou představu, co přesně tento pojem znamená, nebo používala definice, které si navzájem odporovaly. Některé z definic byly nekonzistentní a nepokrývaly problematiku dostatečně výstižným způsobem. Ani odborná literatura nenabízí pevnou definici tohoto termínu. Z toho je patrné, že není jednotná definice tohoto pojmu, i když je hojně užíván.

Dřívější definice startupů byly postaveny převážně na délce existence společnosti. Aby byla společnost startupem, musela být v rané fázi svého vývoje (Ray, 1974). Později byly startupy definovány také omezeným počátečním financováním. Čím ale do jisté míry prochází všechny podniky v rané fázi (Seley, 1981).

V 80. letech minulého století došlo ke změně vnímání tohoto slova. Od tohoto období začal být startup silně spojován s dynamickým vývojem a technologiemi (Cockayne, 2019). Dnes je startup často definován i tím, kolik má zaměstnanců, výší zisku či schopností růst. Nicméně na hranici toho, do kdy může být společnost nazývána startupem, není shoda (Rebehmed, 2013).

Stejně tak není jasná shoda na tom, jak dlouho může být společnost na trhu, aby stále mohla být startupem. Je patrné, že ne vždy bude nový podnik automaticky startup. Zrovna tak může být za startup označována společnost stará dva, tři, pět nebo dokonce osm let od založení. Podle autorky Rebehmed (2013) zůstává společnost startupem většinou tři až pět let od založení. V Kanadě státní agentura ISED (Innovation, Science and Economic Development Canada) stanovuje pro firmu hranici dvou let, od kdy přestává být startupem. Na druhou stranu autoři Tzabbar a Margolis (2017) stanovili ve své práci období startupu na prvních osm let života firmy.

V českém prostředí tento pojem úzce souvisí s programy na podporu podnikání, jako je například projekt Technologická inkubace, realizovaný agenturou CzechInvest. Tento projekt je součástí širší Inovační strategie České republiky 2019–2030 a jeho cílem je podpořit vznik a rozvoj technologických startupů. V rámci tohoto projektu lze žádat o podporu při splnění několika metrik. Na základě těchto metrik lze startup vymežit jako začínající malý nebo střední podnik, který se zaměřuje na vývoj inovativních produktů nebo služeb s vysokým růstovým potenciálem. Společnost je vnímána jako startup pokud, není starší než tři nebo pět let (při splnění podmínek) a působí v perspektivních technologických sektorech, jako jsou kosmické technologie, umělá inteligence, ekoinovace či kulturní a kreativní průmysl (MPO).

Evropská unie přináší program EIC Accelerator. Jedná se o program financování zaměřený na inovativní startupy a malé a střední podniky, který je součástí širšího rámce Horizon Europe, který pomáhá financovat výzkum a vývoj v rámci Evropské unie. Tento program poskytuje finanční podporu podnikům, které mají inovativní produkt nebo službu s potenciálem velkého růstu (European Innovation Council).

I když není jasná shoda na délce života společnosti, po kterou zůstává startupem, shoda o technickém zaměření společnosti či o rychlém růstu a inovativním produktu, aby byla startupem, je. Nově otevřená večerka by těžko byla vnímána jako startup.

S přihlédnutím k literárním pramenům s ohledem na praktickou proveditelnost a schopnost získat data budou za startupy pro analytickou část považovány malé a střední podniky, u kterých neuplynulo více než 5 let od jejich založení. Zároveň bude výběr společností zúžen na vybraná high-tech odvětví o kterých je pojednáváno dále v práci.

1.2. Přínos startupů pro ekonomiku

Startupy hrají klíčovou roli v moderní ekonomice, a to nejen z pohledu zdrojů inovací, ale i z pohledu tvorby pracovních míst, podněcování konkurence nebo řešení ekonomických nerovnováh (Hasani, 2020). Tato kapitola se zaměřuje na tyto i další aspekty jejich přínosu pro ekonomiku.

Jednou z největších předností startupů je jejich schopnost zavádět inovace do ekonomiky. Na rozdíl od velkých firem, které mohou být svázané byrokracií a rigidními procesy, startupy se vyznačují agilní strukturou a flexibilitou. Mnoho úspěšných příkladů ukazuje, že startupy mají schopnost transformovat celé průmyslové sektory. Například Tesla radikálně změnila automobilový průmysl svým zaměřením na elektromobily, Airbnb narušilo tradiční hotelový sektor a SpaceX otevřelo nový pohled v oblasti vesmírného průzkumu a cestování (Rong, 2025).

Startupy mají zásadní význam pro tvorbu pracovních míst. Studie ukazují, že v USA jsou startupy odpovědné za významnou část nově vytvořených pracovních míst, a to i v obdobích ekonomické nestability (Kane, 2010). Startupy sice tvoří pouze malý podíl firem, avšak mají zásadní vliv na celkový růst zaměstnanosti a dynamiku pracovního trhu. Jejich „up-or-out“ dynamika znamená, že jen malá část přežije a expanduje, ale právě tyto úspěšné firmy významně přispívají k ekonomickému růstu a k tvorbě pracovních míst (Yeh, 2023).

Startupy jsou známé svou schopností narušovat tradiční trhy a zvyšovat konkurenci. Příkladem může být vzestup Uberu, který způsobil revoluci v taxislužbách, nebo Netflix, který přeformátoval celý zábavní průmysl. Zvýšená konkurence nutí tradiční společnosti inovovat, a také zlepšovat kvalitu a dostupnost produktů a služeb pro spotřebitele (Rong, 2025).

V období ekonomické nestability mohou startupy pomoci navrátit ekonomice stabilitu. Během hospodářských krizí se ukazuje, že startupy jsou odolnější než velké korporace, a proto mohou pomoci udržet hladinu zaměstnanosti a hospodářský růst. Studie ukazují, že během recesí startupy nadále vytvářejí pracovní místa, zatímco zavedené firmy spíše propouštějí (Kane, 2010).

Startupy jsou důležitým prvkem v procesu šíření znalostí a inovací mezi sektory. Díky své flexibilitě často propojují akademickou sféru, výzkumné instituce a podnikatelské prostředí, čímž usnadňují přenos technologií a know-how. Tento jev, označovaný jako knowledge spillover, zajišťuje, že inovace a nové technologie nejsou izolovány v jednom podniku, ale mají širší dopad na celé odvětví (Rong, 2025).

Startupy přispívají k vyšší efektivitě trhů tím, že zlepšují alokaci zdrojů a podporují dynamiku podnikatelského prostředí. Díky technologickým inovacím a novým obchodním modelům umožňují startupy lepší využití dostupných zdrojů a snižují transakční náklady. Tento efekt je zásadní pro konkurenceschopnost ekonomiky a její dlouhodobou udržitelnost (Rong, 2025).

Podle názoru Hasaniho (2020) je nezbytné, aby byly startupy podporovány ze strany vlád a ekonomických institucí k plnému využití svého potenciálu. To zahrnuje opatření jako zjednodušení regulací, daňové úlevy nebo investice do vzdělávacích programů pro podnikatele. Bez těchto opatření mohou startupy čelit zbytečným překážkám, které omezují jejich růst a schopnost přispívat k ekonomickému rozvoji.

Významným trendem posledních desetiletí je pokles podílu startupů v ekonomice, zejména v USA. Míra zakládání nových firem dlouhodobě klesala, avšak pandemie COVID-19 přinesla překvapivý obrat, kdy došlo k zvýšení počtu nově vzniklých podniků a pracovních míst. Tento vývoj představuje možný zlom v dosavadním trendu klesající podnikatelské dynamiky (Yeh, 2023).

1.3. High-tech startup

Jelikož je práce zaměřena na predikci úspěšnosti u high-tech startupů, je důležité pochopit, jak jsou technologické úrovně ve společnostech rozděleny a jaká odvětví spadají do kategorie high-tech. Technologická klasifikace často rozděluje odvětví do čtyř hlavních kategorií: high-technology, medium-high-technology, medium-low-technology a low-technology, přičemž tyto kategorie odrážejí míru technologické náročnosti výrobních procesů a výzkumně-vývojových aktivit (Eurostat, 2020)

High-tech odvětví je charakterizováno vysokým podílem výdajů na výzkum a vývoj, rychlým technologickým pokrokem a výraznou orientací na inovace (Eurostat, 2021). Podle klasifikace Eurostatu – NACE Rev. 2 (Eurostat, 2020) do této kategorie spadají následující oblasti:

21 - Manufacture of basic pharmaceutical products and pharmaceutical preparations (Výroba základních farmaceutických výrobků a farmaceutických přípravků)

26 - Manufacture of computer, electronic and optical products (Výroba počítačů, elektronických a optických výrobků)

30.3 - Manufacture of air and spacecraft and related machinery (Výroba leteckých a kosmických lodí a souvisejících strojů a zařízení)

Tři výše uvedené odvětvové klasifikace patří do tzv. high-tech průmyslu. Do high-tech odvětví spadají podle Českého statistického úřadu i některé služby. Jsou jimi služby s vysokou technologickou náročností. Těmito službami jsou:

59 a 60 - Audiovizuální činnosti

61 a 62 - Činnosti v oblasti poskytování ICT služeb

63 - Informační činnosti

72 - Výzkum a vývoj

I když se i u těchto odvětví jedná o high-tech sektor, nebudou data společností poskytujících služby do finálního vzorku zahrnuta. Je to kvůli rozdílnosti mezi výrobními společnostmi a společnostmi poskytující služby. Pokud by data byla více heterogenní, je pravděpodobné, že celková predikční schopnost výsledného modelu by byla omezena.

1.4. Vývoj high-tech sektoru

Tabulka číslo 1 zachycuje množství podniků v letech 2020, 2021 a 2022 v rámci jednotlivých odvětví, která patří do high-tech sektoru. V první části tabulky jsou zachycena data v absolutních číslech za Českou republiku, zatímco v druhé části za celou oblast EU27. Je patrné, že nejvíce společností, které spadají do high-tech sektoru, jsou ty, které se zabývají výrobou počítačů, elektronických a optických výrobků. Odvětví jakožto celek roste, nicméně v rámci Evropské unie je tento růst téměř zanedbatelný, protože dosahuje růstu pouze kolem 0.1 %. Naopak v Česku je mezi lety 2020 a 2022 růst znatelnější. Množství společností v těchto odvětví souhrnně vzrostlo o téměř 5 %, přičemž lze předpokládat, že tyto nové

společnosti byly vnímány právě jako startupy. Toto zjištění je v souladu s Ministerstvem průmyslu a obchodu (2019), podle kterého je Česká republika zemí startupů. Ministerstvo průmyslu a obchodu plánuje v rámci své Inovační strategie České republiky 2019-2030, aby se Česko stalo inovačním lídrem.

Tabulka č. 1: Vývoj počtu podniků v high-tech odvětví

(Zdroj: vlastní zpracování dle EUROSTAT)

	Odvětví	2020	2021	2022
Česko	Celkový počet společností	1 254 110	1 292 436	1 310 320
	Výroba základních farmaceutických výrobků a farmaceutických přípravků	86	90	86
	Výroba počítačů, elektronických a optických výrobků	3 300	3 362	3 446
	Výroba leteckých a kosmických lodí a souvisejících strojů a zařízení	93	102	114
EU	Celkový počet společností	31 034 442	32 251 876	32 721 956
	Výroba základních farmaceutických výrobků a farmaceutických přípravků	4 064	4 047	4 000
	Výroba počítačů, elektronických a optických výrobků	36 800	nezveřejňuje	36 800
	Výroba leteckých a kosmických lodí a souvisejících strojů a zařízení	1 469	1 532	1 588

Z tabulky číslo 2 je patrné, že podniky v high-tech sektoru nepředstavují velké procento v rámci všech podniků. Ukazuje se, že oproti průměru EU je v Česku podíl takovýchto podniků podstatně vyšší. Zároveň lze z tabulek také vyčíst, že podíl high-tech podniků na počtu všech podniků v Evropské unii mezi lety 2020 až 2022 klesá. V České republice se jedná spíše o stagnaci, což je způsobeno hlavně poměrně velkým procentním nárůstem podniků v odvětví výroby leteckých a kosmických lodí a souvisejících strojů a zařízení.

Tabulka č. 2: Podíl high-tech podniků v ekonomice

(Zdroj: vlastní zpracování dle EUROSTAT)

	Odvětví	2020	2021	2022	Rozdíl mezi lety 2020 až 2022
Česko	Celkový počet společností	100%	100%	100%	
	Výroba základních farmaceutických výrobků a farmaceutických přípravků	0.00686%	0.00696%	0.00656%	-4.290%
	Výroba počítačů, elektronických a optických výrobků	0.26313%	0.26013%	0.26299%	-0.055%
	Výroba leteckých a kosmických lodí a souvisejících strojů a zařízení	0.00742%	0.00789%	0.00870%	17.322%
EU	Celkový počet společností	100%	100%	100%	
	Výroba základních farmaceutických výrobků a farmaceutických přípravků	0.01310%	0.01255%	0.01222%	-6.651%
	Výroba počítačů, elektronických a optických výrobků	0.11858%	nezveřejňuje	0.11246%	-5.157%
	Výroba leteckých a kosmických lodí a souvisejících strojů a zařízení	0.00473%	0.00475%	0.00485%	2.526%

1.5. Vymezení úspěšnosti startupu

Podle Failory přibližně 90 % nových startupů končí neúspěchem. Tato čísla ukazují na vysokou rizikovost, které podnikatelé i investoři čelí při zakládání nových firem či při investování. První rok podnikání je kritický, protože až 20 % startupů zavře už v prvním roce. Vysoká míra neúspěchu pokračuje i v následujících letech, kdy 50 % firem končí do pátého roku existence. V dlouhodobém horizontu pouze 10 % startupů přežije a podaří se jim udržet v podnikání a dosáhnout trvalého růstu. Tyto statistiky zdůrazňují náročnost a rizikovost podnikání v oblasti startupů, kde mnoho firem z různých důvodů nedokáže přežít v dlouhodobém horizontu.

Mezi faktory, které vedou k neúspěchu startupů, patří například nedostatek poptávky na trhu (Failory, 2022). Pokud podnik nenabízí řešení skutečného problému nebo jeho produkt neodpovídá potřebám trhu, je velmi těžké zaujmout a získat zákazníky. Dalším zásadním problémem, kterým startupy čelí, jsou problémy s cash flow, které se ukazují jako hlavní příčina selhání. Podle údajů 82 % neúspěšných podniků čelí právě těmto finančním potížím (Fundera, 2023), což znamená, že mnohé startupy neudrží stabilitu, pokud se jim nedaří

správně odhadnout své příjmy a výdaje. Tento problém je často způsoben nerealistickými odhady prodeje nebo špatným řízením financí, což může vést k vážným problémům s likviditou a zamezit dalšímu rozvoji podniku.

1.5.1. Možnosti predikce

Startupy oproti zavedeným podnikům ve velké míře zanikají, jak je patrné z předešlé kapitoly. Zánik společnosti lze jednoznačně označit za neúspěch. Přestože neúspěch lze poměrně snadno definovat jako zánik firmy, vymezení úspěchu je mnohem složitější. Startup nemusí být úspěšný pouze tím, že přežije.

Jedním z důležitých aspektů při posuzování úspěchu startupu je volba vhodné metriky. Zatímco některé práce hodnotí úspěch podle míry růstu nebo dosaženého zisku, jiní autoři jej definují podle typu a kvality dosaženého exitu – tedy výstupu investora ze společnosti se získáním investovaných prostředků a zisku. Tento přístup zvolili například Gompers, Kovner a Lerner (2009).

Dále Gompers, Kovner a Lerner (2009) identifikovali, že významným faktorem ovlivňujícím úspěšnost startupu je úroveň specializace a zkušeností investorů, konkrétně venture kapitálových společností a jednotlivých investorů v těchto firmách. Jejich analýza ukázala, že startupy podporované investory s hlubokou specializací na konkrétní odvětví měly vyšší pravděpodobnost úspěchu.

U zavedených podniků lze relativně dobře predikovat bankrot pomocí různých bankrotních modelů, jako jsou například Altmanovo Z-skóre, Taflerův model nebo Indexy IN či další metody založené na finančních ukazatelích. Tyto modely pracují s ukazateli jako zadluženost, rentabilita, likvidita či obraty a na základě jejich vývoje určují pravděpodobnost úpadku podniku. Pokud však tyto modely aplikujeme na startupy, výsledky budou zavádějící. Většina startupů totiž v počáteční fázi podnikání bude vykazovat nízkou rentabilitu, vysokou zadluženost a často i negativní cash flow. Z pohledu tradičních bankrotních modelů by tak velká část startupů byla označena jako vysoce riziková nebo předurčená k bankrotu, přestože některé z nich mohou mít značný růstový potenciál a stát se v budoucnu úspěšnými.

Z tohoto důvodu je nezbytné hledat alternativní přístupy k predikci úspěšnosti startupů. Tyto přístupy se zaměřují na jiné ukazatele, které lépe reflektují dynamiku a specifika startupového prostředí. Aby byla situace startupu co nejlépe definována, je vhodné využít kombinaci podnikově specifických ukazatelů (a to jak finančních, tak nefinančních) a ukazatelů vnějšího prostředí, ve kterém se konkrétní podnik nachází. Je patrné, že predikce úspěšnosti startupu vyžaduje komplexní přístup, který kombinuje jak finanční analýzu, tak i měření růstu či analýzu prostředí.

O predikci úspěšnosti startupů se už pokoušela spousta autorů, přičemž způsoby, kterými chtěli jimi vymezenou úspěšnost měřit, se často velmi lišily. V následující části práce jsou některé z nich popsány.

1.5.1.1. Studie 1 (Exploring-the-factors-of-startup-success-and-growth)

Tato studie autorů Okrah, Nepp a Agbozo (2018) se zabývá faktory, které ovlivňují úspěch a růst startupů. Autoři využili data firem ze 13 vyspělých evropských zemí a provedli regresní analýzu pro určení vztahů mezi faktory ovlivňujícími inovace a financování startupů. Jako úspěch studie definuje právě schopnost podniku neustále inovovat a získávat financování. Podle autorů je inovace klíčovým faktorem úspěchu startupů, protože startupy, které investují do výzkumu a vývoje, mají větší šanci na dlouhodobý úspěch. Nedostatek inovací může být hlavní příčinou krachu. Pro rozvoj startupu je zároveň také důležitá dostupnost kapitálu. Studie si stanovuje několik proměnných, u kterých se snaží definovat vliv výše těchto proměnných na úspěch startupu tedy na schopnost inovovat a získávat finance. Jako determinanty úspěchu určuje studie výši obratu, otevřenost trhu (tedy míru náročnosti vstupu na trh), míru vládní podpory podnikání, míru daňové zátěže, dynamiku vnitřního trhu a další faktory.

Tyto faktory autoři volí, jelikož investoři často sledují právě tyto proměnné, aby minimalizovali riziko investice.

V rámci studie bylo odvozeno několik závěrů. Na schopnost získávat finance má velký pozitivní vliv obrat, míra otevřenosti trhu a míra vládní podpory podnikání. Pokud tyto proměnné rostou, jsou investoři více ochotni financovat dané startupy. Studie také odhalila

negativní vliv tržní dynamiky na schopnost získat finance. Důvodem může být to, že na proměnlivém trhu je nutné se přizpůsobovat, pokud to podnik nezvládne, může zaniknout, což obecně zvyšuje míru rizika pro investory a odrazuje je od investování v rámci takových lokalit. Studie poukazuje na provázanost dvou faktorů úspěchu, tedy schopnosti získat finance a schopnosti inovovat. Tvrdí, že pokud má podnik přístup k financím bude spíše inovovat, což vytváří pozitivní vztah zmiňovaných proměnných i s tímto faktorem úspěchu.

1.5.1.2. Studie 2 (Econometric Estimation of the Factors That Influence Startup Success)

Studie autorů Carlos Díaz-Santamaria a Jacques Bulchand-Gidumal (2021) se také zabývá problematikou úspěchu startupů a identifikací klíčových faktorů, které tento úspěch ovlivňují. Studie se zaměřuje zejména na technologické startupy a snaží se na základě literatury a empirických dat určit, jak lze úspěch startupů měřit a jaké faktory jej ovlivňují. Studie analyzuje data 340 startupů ze Španělska a stejně jako studie předchozí stanovuje jakožto úspěch dvě kritéria. Prvním kritériem je dosažení významného obratu, který autoři definují jako překročení hranice 100 000 EUR ročního příjmu. Druhé kritérium úspěchu je totožné jako u předchozí studie. Je jím schopnost startupu získat financování. Výběr těchto dvou metrik vychází nejen z literatury, ale i z rozhovorů s padesáti podnikateli a patnácti investory do rizikového kapitálu, kteří byli dotazováni na jejich vnímání úspěchu startupů.

Výsledky analýzy ukazují, že mezi nejvýznamnější faktory ovlivňující úspěch startupu patří především jeho lokalita, věnování se podnikání na plný úvazek, věk startupu, přítomnost investorů mezi spoluzakladateli a předchozí podnikatelské zkušenosti zakladatelů. Lokalita hraje roli zejména v dosažení významného obratu – startupy sídlící ve velkých podnikatelských centrech mají výrazně vyšší šance na dosažení vysokých příjmů než ty, které se nacházejí v méně rozvinutých regionech. Poukazují na to, že přístup k investorům, infrastruktura a podnikatelským sítím je pro ekonomický úspěch startupu zásadní.

Zajímavým zjištěním je vztah mezi inkubátory a akcelerátory a úspěchem startupů. Autoři zjistili, že startupy, které prošly těmito programy, mají vyšší pravděpodobnost získání financování, ale zároveň nižší šanci na dosažení významného obratu. To naznačuje, že

inkubátory mohou být užitečné v rané fázi startupů, kdy pomáhají s přístupem k mentorům, investorům a odbornému poradenství, ale mohou startupy také udržovat v závislosti na externí podpoře, což může zpomalit jejich růst.

Důležitým faktorem ovlivňujícím získání financování je také přítomnost neřídících investorů mezi zakladateli. Startupy, které již mají investory v zakladatelském týmu, mají výrazně vyšší šanci na další investice. Investoři obvykle vnímají přítomnost zkušených podnikatelů a investorů jako signál nižšího rizika, což usnadňuje přístup k dalšímu kapitálu.

Další faktory, jako je počet zaměstnanců nebo technologické vzdělání zakladatelů, neměly podle studie významný dopad na úspěch startupů.

1.5.1.3. Studie 3 (Predicting Startup Survival Using First Years Financial Statements)

Autoři Yolanda Fuertes-Callén, Beatriz Cuellar-Fernández a Carlos Serrano-Cinca (2020) se zabývali otázkou, zda lze předpovědět přežití startupů na základě finančních výkazů z jejich prvních let existence. Autoři se zaměřují na to, jak finanční ukazatele ovlivňují pravděpodobnost, že firma zůstane na trhu i po několika letech. Vycházejí přitom z teorie organizační ekologie, která tvrdí, že firmy s lepšími výchozími podmínkami mají vyšší šanci na dlouhodobé přežití, zatímco ty, které začínají se špatnými finančními výsledky, často brzy zaniknou.

Studie analyzuje 6167 španělských startupů, které byly sledovány po dobu osmi let od svého založení. Výzkum ukázal, že firmy, které přežily osm let, měly již ve druhém roce existence lepší finanční ukazatele než ty, které nakonec zkrachovaly. Mezi klíčové faktory patřila rentabilita, produktivita, likvidita, zadlužení a velikost firmy. Zejména rentabilita se ukázala jako silný prediktor přežití, protože společnosti, které dosahovaly zisku již na začátku svého podnikání, měly mnohem větší pravděpodobnost dlouhodobého fungování. Podobně firmy s lepší likviditou a nižším zadlužením měly vyšší šanci na přežití, zatímco silně zadlužené podniky měly tendenci zanikat rychleji.

Autoři ve své studii použili různé statistické metody, včetně logistické regrese, neuronových sítí a rozhodovacích stromů, aby vytvořili modely pro predikci přežití startupů. Tyto modely sice vykazovaly určitou predikční schopnost, ale nebyly tak přesné jako tradiční modely používané pro predikci bankrotu u zavedených firem. Přesto se ukázalo, že analýza finančních výkazů již ve druhém roce existence startupu může investorům a analytikům poskytnout cenné informace o budoucí životaschopnosti podniku.

Jedním z klíčových zjištění článku bylo potvrzení teorie organizační ekologie, která tvrdí, že firmy s dobrými výchozími podmínkami přežívají ve větší míře než ty, které začínají s problémy. Výzkum tak naznačuje, že účetní data mohou být užitečným nástrojem pro predikci úspěchu startupů, i když nejsou jediným faktorem, který by měl být při hodnocení nových podniků brán v úvahu.

Ze studie plyne, že by investoři měli pečlivě analyzovat finanční výkazy startupů již v jejich raných fázích, protože silné finanční základy v počátečních letech mohou být dobrým indikátorem budoucího úspěchu. Zároveň by měli podnikatelé dbát na finanční zdraví svých firem hned od začátku, protože nedostatečná ziskovost, špatná likvidita nebo vysoké zadlužení mohou výrazně snížit jejich šanci na dlouhodobé přežití. Studie rovněž ukazuje, že ačkoliv některé startupy mohou být zpočátku ztrátové, pokud mají dostatečné finanční rezervy a nízké zadlužení, mají stále vysokou šanci na úspěch.

1.5.2. Ziskovost jako metrika úspěšnosti

Debata o tom, co přesně definuje úspěch startupu, představuje nevyřešenou otázku v oblasti podnikání i akademického výzkumu. V různých přístupech k měření úspěchu startupů se objevují různé metriky, přičemž některé zdůrazňují rychlý růst, jiné objem získaných investic, další pak technologickou inovaci či expanzi na nové trhy. Jedním z tradičních a stále diskutovaných ukazatelů je však ziskovost, která v mnoha ekonomických teoriích zůstává klíčovým měřítkem úspěchu podniku. Přestože se v posledních dekadách do popředí dostaly jiné přístupy, například zaměřené na rychlý růst startupů či jejich valuaci v očích investorů,

stále více výzkumů ukazuje, že dlouhodobý úspěch startupu je úzce propojen s jeho schopností generovat zisk (Kiviluoto, 2011).

Podle Kiviluota (2011) mnoho startupů, zejména v oblasti technologických inovací, operuje s myšlenkou, že růst je hlavní prioritou a že ziskovost se dostaví až v pozdější fázi. Tento přístup je posilován kulturou rizikového kapitálu, který často hodnotí startupy podle jejich schopnosti přitahovat další investice spíše než podle jejich schopnosti samostatně fungovat na trhu. Tento trend však přinesl i řadu problémů – mnoho rychle rostoucích startupů nakonec nedosáhlo dlouhodobé udržitelnosti, protože jejich obchodní model nebyl dostatečně profitabilní, což vedlo k jejich zániku nebo k závislosti na neustálém přísunu externího kapitálu.

Studie dále uvádí, že startup, který je schopen dosahovat profitabilního růstu, má vyšší pravděpodobnost dlouhodobého přežití než startup, který se zaměřuje výhradně na růst bez ohledu na zisk. Výzkum finských high-tech startupů ukázal, že firmy, které měly od počátku ziskový obchodní model, měly lepší šanci na přežití a udržení se na trhu než ty, které se spoléhaly na neustálé investice jako hlavní zdroj financování. Tento výzkum poskytuje silnou empirickou oporu pro myšlenku, že profitabilita by měla být jedním z klíčových kritérií pro hodnocení úspěchu startupů. Myšlenka stojí na analýze vzorku finských high-tech startupů.

Tato zjištění naznačují, že pokud má být úspěch startupu predikován objektivně, měla by být profitabilita klíčovou součástí predikčních modelů.

Studie Kiviluota (2013) se zabývá podobnou otázkou jako studie předchozí. A to, zda je růst firmy skutečným indikátorem jejího úspěchu, nebo zda je tato představa pouze mýtem, který není podložen objektivními ekonomickými ukazateli. Přístup hodnocení úspěšnosti startupu podle růstu podporují zejména investoři rizikového kapitálu, pro které je růst signálem zhodnocení jejich investic. Autor argumentuje, že profitabilita a udržitelnost podnikání jsou spolehlivějšími ukazateli dlouhodobého úspěchu. V rámci svého výzkumu analyzoval dlouhodobá data o malých a středních firmách a hledal souvislosti mezi růstem a dalšími metrikami podnikatelského úspěchu.

Ve studii byla analyzována dlouhodobá data malých a středních podniků. Výzkum byl založen na kvantitativní analýze dat, přičemž klíčovými proměnnými byly tempo růstu tržeb a ziskovost (čistý zisk, hrubá marže, EBIT).

Jedním z hlavních závěrů studie je, že tempo růstu firmy není spolehlivým ukazatelem její dlouhodobé úspěšnosti. Výzkum ukázal, že mnoho firem, které rychle rostly v počáteční fázi, se následně dostalo do finančních problémů a nepřežilo. Tento jev byl obzvláště patrný u startupů, které se soustředily na agresivní expanzi bez jasného ziskového modelu.

Ziskové firmy měly až 70% vyšší pravděpodobnost přežití v horizontu 10 let než firmy, které sice rostly, ale nebyly ziskové. Startupy, které dosáhly pozitivního cashflow v prvních letech existence, měly třikrát vyšší pravděpodobnost přežití než firmy, které tohoto nedosáhly.

Z těchto výsledků vyplývá, že profitabilita není pouze „výsledkem růstu“, ale sama o sobě je klíčovým faktorem podnikatelského úspěchu. Startupy by měly od začátku pracovat na udržitelném obchodním modelu, a ne pouze na rychlém růstu. Investoři by měli více zohledňovat ziskové marže a cashflow startupu, místo aby se soustředili výhradně na jeho tržní expanzi (Kiviluoto, 2013).

1.5.3. Definice úspěšnosti startupu pro model

Úspěšnost startupu je koncept, který je v odborné literatuře definován různými způsoby. Startupy, coby mladé a inovativní společnosti s vysokým růstovým potenciálem, mají specifické potřeby, a proto může být úspěch různých startupů vnímán poměrně rozdílně.

Jedním z často uváděných kritérií je schopnost získat financování. (Baskoro a kol., 2022; Díaz-Santamaría a Bulchand-Gidumal, 2021). Toto kritérium odráží důvěru investorů ve startup a v jeho předmět podnikání. Získání financování je pro startupy velmi důležité, protože jen tak dokážou na trhu přežít a prosadit se.

Dalším faktorem je schopnost růstu, a to jak v rámci rozšiřování zákaznické základny či obratu, tak geografického dosahu. Startup, který rychle získává nové klienty nebo vstupuje na zahraniční trhy, je často považován za úspěšný. Úspěch může být rovněž definován z

hlediska získání podílu na trhu. Startupy, které dokážou vytlačit zavedené hráče nebo si zajistit významnou část tržního podílu, jsou vnímány jako úspěšné (Kiviluoto, 2013).

Na základě literární rešerše s přihlédnutím k praktické proveditelnosti a schopnosti získat data, budou jako úspěšné označeny ty startupy, které splní požadavek ziskovosti. Důvodem je to, že z literatury plyne, že právě ziskovost má na přežití podniku velmi silný vliv.

Je patrné, že nestačí zisk vygenerovat pouze jednou za sledované období. Podnik musí být schopen zisku dosáhnout, ale také si ho udržet. Je potřeba ale také přihlížet k tomu, že společnosti v rané fázi životního cyklu mají tendenci být ve ztrátě, což samo o sobě také nemusí znamenat neúspěch. Proto je požadavek na dosažení zisku ve všech analyzovaných letech daného období také zamítnut. Nicméně je potřeba přihlídnout ke skutečnosti uvedené výše, a to k té, že firmy ziskové již v počátku své existence mají větší pravděpodobnost přežití. Kvůli těmto argumentům bylo jako kritérium úspěchu startupu pro tuto práci zvoleno dosažení zisku ve 3 z 5 analyzovaných období.

1.6. Faktory ovlivňující úspěch startupů

Úspěch startupů je podmíněn řadou faktorů, které budou v rámci práce rozděleny do dvou hlavních kategorií. Jsou jimi faktory prostředí a podnikově specifické faktory. Faktory prostředí zahrnují makroekonomické a institucionální podmínky země, ve které startup působí. Tyto faktory mohou zásadně ovlivnit možnosti růstu, dostupnost kapitálu a lidských zdrojů i celkovou konkurenceschopnost podnikání. Naopak podnikově specifické faktory reflektují individuální charakteristiky startupu, jako jsou jeho finanční zdraví, růstové ukazatele nebo organizační struktura.

Mezi faktory prostředí může patřit např. HDP na obyvatele v zemi usazení startupu, míra nezaměstnanosti a Ease of Doing Business Index, který měří snadnost podnikání v dané zemi. Díky těmto ukazatelům bude model schopen reflektovat dostupnost financování, spotřebitelskou poptávku i regulatorní náročnost podnikání. Další z prediktorů, který bude vyzkoušen, je růst odvětví, ve kterém startup působí. Nejedná se už o zasazení startupu do prostředí definovaného státem, ale daným odvětvím, a to v rámci celé Evropské unie.

Je důležité zahrnout i podnikově specifické faktory, jelikož bez těch, by model dával každému podniku v dané zemi a odvětví stejnou šanci na úspěch. Podnikově specifických faktorů je možné vybrat mnoho, nicméně cílem je vybrat takové ukazatele, které reflektují jak problémové oblasti startupů, tak oblasti, o kterých literatura tvrdí, že jsou pro úspěch stěžejní. Je tedy možné zaměřit se na cashflow a schopnost splácet své závazky, schopnost růst nebo schopnost získávat financování. Proto mohou podnikově specifické faktory zahrnovat například existenci dceřiné společnosti nebo klíčové finanční ukazatele, jako je meziroční růst vlastního kapitálu, meziroční růst obrátu, meziroční růst čistého pracovního kapitálu nebo běžnou likviditu. Tyto faktory odrážejí finanční stabilitu a dynamiku rozvoje startupu.

Následující část práce podrobněji popisuje prediktory uvedené v tabulce 3 a na základě literatury či logických úvah předpokládá jejich vliv na úspěšnost startupů.

Tabulka č. 3: Seznam potenciálních prediktorů

(Zdroj: vlastní zpracování)

Prediktor
HDP na obyvatele ve státě sídla
Míra nezaměstnanosti ve státě sídla
Index EDB ve státě sídla
Existence dceřiné společnosti
Růstu odvětví
Růst vlastního kapitálu
Růst obrátu
Běžná likvidita
Růst pracovního kapitálu

Existuje předpoklad, že jelikož **HDP na obyvatele** reprezentuje ekonomickou úroveň státu, kde má společnost své sídlo, bude úspěšnost těchto společností ovlivněna právě úrovní HDP na obyvatele. Vliv může být jak pozitivní, tak i negativní. (Sahu, Kshatriya, 2024)

Vyšší HDP na obyvatele bude zpravidla doprovázeno vyšší kupní silou lidí, což může zvýšit poptávku a příležitosti pro nové společnosti. Neopomenutelnou výhodou je i lepší rozvinutější infrastruktura v zemích s vyšším HDP, což může začínající firmě usnadnit rozvoj

a růst. Je možné, že v oblastech s vyšším HDP na obyvatele budou větší šance na přístup k venture kapitálu, což může podpořit růst nových firem. (Callend)

S vyšším HDP na obyvatele můžou ovšem přicházet i výzvy. V regionech s vyšším HDP na obyvatele je často vyšší konkurence, takže může být pro začínající firmu náročné se prosadit. Musí se vypořádat s již známými a zavedenými společnostmi, které mají větší zdroje. Další nevýhodou může být to, že v oblastech s vyšším HDP na obyvatele jsou často vyšší náklady na provoz a rozvoj podnikání (např. nájmy, mzdy, daně) (Matoušková, 2000).

Autoři Sahu a Kshatriya (2024) ve své práci přichází se zjištěním, že s růstem HDP je významně spojena míra přežití startupů. V jejich studii je uvedeno, že při růstu HDP byla zaznamenána i zvýšená míra přežití startupů. Tento jev bude dále v práci analyzován.

Dalším potenciálním prediktorem je **míra nezaměstnanosti** v daném státě. U míry nezaměstnanosti existuje jak předpoklad, že bude úspěšnost startupů ovlivňovat pozitivně, tak že bude úspěšnost ovlivňovat negativně. Na problematiku míry nezaměstnanosti se v souvislosti s tímto tématem dá nahlížet z několika úhlů.

Nezaměstnanost představuje podle OECD podíl pracovní síly bez práce, přičemž pracující sílu představují jak lidé pracující, tak lidé bez práce. Aby byl někdo označen jako nezaměstnaný, musí být v produktivním věku, aktivně hledat práci a být připraven do ní do 14 dní nastoupit.

Když klesá nezaměstnanost, klesá tím nabídka práce ze strany domácností. Aby si firmy udržely talenty nebo získaly nové zaměstnance, jsou nuceny zvyšovat mzdy. Rostoucí mzdy mohou být často přínosné, avšak v některých případech mohou představovat i problém. Například malé firmy, které nemají dostatečné marže, mohou mít problém se s rostoucími mzdami vypořádat. Vedlejším efektem rostoucích mezd je však to, že některé malé firmy jsou nuceny najímat méně kvalifikované pracovníky, což vede ke snížení produktivity (Buckley, 2022).

Právě s tímto problémem se mohou při nízké nezaměstnanosti potýkat startupy. Vzniká tedy předpoklad, že s klesající mírou nezaměstnanosti bude klesat i pravděpodobnost úspěchu startupu. Tento předpoklad bude v práci dále analyzován.

Nicméně další pohled na vztah mezi nezaměstnaností a úspěchem startupů ukazuje, že vliv může být i opačný. Autoři Holmes, Hunt a Stone (2008) přicházejí s tím, že vyšší míra nezaměstnanosti je často spojena s nižší poptávkou v ekonomice, což může startupům ztěžovat přežití v prvních letech existence. Zároveň vyšší nezaměstnanost vede k většímu počtu nově vzniklých podniků, protože někteří lidé, kteří si nemohou najít práci berou založení vlastní firmy jako náhradní řešení. Tyto nově založené firmy však často vznikají, protože jsou často vedeny osobami s nižšími manažerskými schopnostmi a omezenými zdroji. V důsledku toho je pravděpodobné, že vyšší míra nezaměstnanosti v době založení startupu zvyšuje riziko jeho neúspěchu v prvních letech fungování.

Tento druhý pohled zase vytváří předpoklad, že nezaměstnanost bude negativně působit na úspěch startupů. Vliv míry nezaměstnanosti bude analyzován a vyhodnocen níže v práci.

Ease of Doing Business Index (Index snadnosti podnikání) pozoruje snadnost podnikání v daných státech. Je možné, že úspěšnost startupů bude na této hodnotě pozitivně záviset. Tato myšlenka bude analyzována dále v práci.

Ease of Doing Business je žebříček, který hodnotí ekonomiky podle toho, jak snadné je v nich podnikat. Rozsah hodnocení zahrnuje 190 ekonomik. Krom žebříčku stanovuje i konkrétní číslo, které závisí na tom, jak příznivé prostředí pro podnikání ve státu je a jak moc státy zasahují svými regulacemi do svobody podnikatelů. Vyšší hodnocení znamená, že prostředí je pro podnikatele vstřícnější (World Bank, 2020a).

Hodnocení je založeno na součtu deseti skóre z daných oblastí, každá oblast může nabývat různých hodnot. Následně jsou všechny hodnoty ještě vynásobeny příslušnými vahami, což po sečtení dá konečnou výši tohoto indexu. Na základě výše indexu, kterou státy dosáhly, je poté tvořen žebříček. Oblasti, které do indexu vstupují jsou např. získávání stavebního povolení či zakládání podniku, kde se hodnotí náročnost procesu nebo třeba minimální nutný kapitál. Dále je počítáno s náročností připojení k elektřině, registrace nemovitosti nebo získání úvěru. Do indexu ještě vstupuje daňová zátěž, řešení platebních neschopností a další faktory. (World Bank, 2020b)

Předpoklad, že vyšší index EDB – tedy lepší podnikatelské prostředí, pozitivně souvisí s úspěšností startupů vychází ze závěrů studie autorů Okrah, Nepp a Agbozo (2018). Autoři stanovují jako determinanty úspěchu, mimo jiné, i míru vládní podpory podnikání či míru daňové zátěže, což jsou aspekty, které jsou v rámci indexu zohledněny.

V rámci tvorby prediktivního modelu úspěchu startupů bude jako jeden z klíčových prediktorů využita **míra růstu odvětví** v roce předcházejícím roku dosažení úspěchu, a to zpětně za 4 roky. Tento ukazatel je vnímán jako faktor reflektující celkovou dynamiku trhu a jeho atraktivitu pro nové subjekty.

Předpokládá se, že vyšší míra růstu odvětví pozitivně ovlivní pravděpodobnost úspěchu startupu, protože rostoucí trh poskytuje více příležitostí k expanzi, usnadňuje přístup ke kapitálu a vytváří vyšší poptávku. Naopak při stagnaci nebo poklesu odvětví může docházet ke snižování ochoty investorů financovat nové projekty a ke zvyšování konkurence mezi zavedenými hráči, což pravděpodobně povede k nižší pravděpodobnosti dosažení úspěchu.

Dynamika růstu v jednotlivých sektorech bude v modelu použita jako aproximace tržních podmínek, které ovlivňují startupy v klíčových fázích jejich vývoje. Tímto způsobem bude umožněno lépe zachytit vnější faktory, jež mohou přispět k jejich úspěchu či neúspěchu.

Proměnná „**existence dceřiné společnosti**“ říká, zda má startup dceřinou společnost nebo nikoliv (1/0). Proměnná byla tedy vyjádřena binárně. Její zahrnutí umožňuje zjistit, zda organizační struktura startupu má vliv na jeho úspěšnost. Je potřeba podtrhnout, že z celkového množství startupů jich mělo dceřinou společnost jen poměrně málo. Předpoklad pro zahrnutí proměnné do modelu je ten, že pokud společnost zakládá dceřinou společnost eventuálně investuje do vlastního kapitálu společnosti jiné, bude mít spíše lepší finanční situaci a bude častěji úspěšná než neúspěšná.

Dalším potenciálním prediktorem je **růst vlastního kapitálu**. Předpoklad, že pokud startupu poroste rychleji jeho vlastní kapitál, tak bude mít tendenci být úspěšnější, pramení ze studií autorů Okrah, Nepp a Agbozo (2018) a autorů Carlos Díaz-Santamaria a Jacques Bulchand-Gidumal (2021). Tyto studie vnímají schopnost získávat financování jako jeden z nejvíce stěžejních faktorů úspěchů startupu.

Zvyšování hodnoty vlastního kapitálu podniku může být důsledkem zvýšení zisků nebo také přitahování nových investic. Jak zisk, tak nové investice jsou literaturou vnímány jako gros problematiky úspěšnosti startupů. Proto je na místě uvažovat s touto proměnou.

Tato proměnná vstupuje do modelu jako růst vlastního kapitálu společnosti v procentech, a to mezi prvním a čtvrtým rokem od založení podniku.

Stejně jako předchozí prediktor, byl i **růst obratu** vybrán na základě studií autorů Okrah, Nepp a Agbozo (2018) a autorů Carlos Díaz-Santamaria a Jacques Bulchand-Gidumal (2021). Obě studie vyzdvihují význam růstu obratu startupu na jeho úspěch. Tento vztah by měl být dle studií pozitivní. Jinými slovy: pokud obrat meziročně roste, roste i šance na úspěch.

Důvodem je předpoklad, že pokud podniku roste obrat, roste mu nejspíše i počet zákazníků či zakázek. Autoři poukazují na jev, že takové startupy jsou pak spíše schopny získat finance, a to ať už jako výsledek své činnosti, tak z cizích zdrojů (od bank či investorů).

Podobně jako u předchozího prediktoru, byl zde sledován růst mezi prvním a čtvrtým rokem. Proměnná byla zachycena v procentech.

Dalším prediktorem je **běžná likvidita** na konci čtvrtého roku od založení podniku. Tento prediktor je binární a vyjadřuje, zdali podnik dosahuje běžné likvidity alespoň ve výši 1, což značí, že je schopen svými krátkodobými aktivy pokrýt krátkodobé závazky. Literatura sice často uvádí optimální hranici od 1,5, nicméně začínající podniky mívají často vyšší zadluženost, proto byla hodnota zvolena nižší. Pokud tedy podnik dosáhne této likvidity vyšší nebo rovno 1 vstupuje do modelu jako 1, pokud nedosáhne, vstupuje jako 0.

Tento prediktor byl zvolen na základě studie autorů Yoland Fuertes-Callén, Beatriz Cuellar-Fernández a Carlos Serrano-Cinca (2020). Tito autoři ve svém výzkumu došli k závěrům, které poukazují na to, že mladé podniky s vyšší likviditou měly významně vyšší šanci na přežití než podniky s nedostatkem likvidních aktiv. Kvůli tomu je očekáváno, že bude i v rámci této práce likvidita vykazovat kladný vliv na úspěch startupů.

I u proměnné „**růst čistého pracovního kapitálu**“ byl sledován růst mezi prvním a čtvrtým rokem od založení. Čistý pracovní kapitál je definován jako rozdíl mezi krátkodobými aktivy

a krátkodobými pasivy. Tato proměnná byla zvolena, jelikož rostoucí pracovní kapitál zpravidla znamená zlepšování finančního stavu podniku. Proměnná je zachycena v procentech, aby nebyla brána v potaz velikost podniku (kdy větší podniky budou mít pravděpodobně vyšší pracovní kapitál), ale aby se do modelu promítla schopnost podniku stabilně zlepšovat svou finanční situaci. Zmíněná literatura zároveň poukazuje na vysoký význam nízké zadluženosti a vysoké likvidity na úspěch (Callén, Fernández a Cinca, 2020).

U tohoto prediktoru je očekáván pozitivní vliv na úspěch startupů. Toto tvrzení bude v práci dále prozkoumáno.

2. Analýza high-tech odvětví

V dynamicky se měnícím podnikatelském prostředí hraje růst odvětví zásadní roli při úspěchu startupů. Literatura potvrzuje, že podniky operující v rychle rostoucích odvětvích mají větší příležitosti k rozvoji, inovacím a získávání konkurenční výhody.

Z teoretického hlediska lze růst odvětví chápat jako indikátor atraktivity tržního prostředí. Podle modelů, na nichž se opírají například práce Audretsch a Thurik (2001), může rychlý růst odvětví zvyšovat inovativní aktivitu a snižovat bariéry vstupu nových subjektů. Tato teorie je dále rozvíjena v literatuře, kde Acs a kol. (2006) upozorňují na význam dynamických trhů pro podnikatelskou aktivitu a růst nových firem. V kontextu startupů tedy rychlý růst obratu představuje nejen měřítko ekonomického potenciálu, ale i prostředí, ve kterém mají nové podniky větší šanci na úspěšné etablování a expanzi.

Druhá část této kapitoly se zaměřuje na analýzu meziročního růstu obratu v rámci vybraných odvětví za posledních deset let. V tabulce číslo 4 jsou uvedeny sumy obrátů všech startupů v rámci Evropské unie, které jsou dostupné v databázi Orbis Europe, a to za jednotlivá odvětví a jednotlivé roky. Pro zajištění širšího pohledu byla kromě individuální analýzy těchto sektorů vytvořena i souhrnná hodnota zahrnující sumu všech high-tech odvětví. Tento přístup umožňuje posoudit, zda tato odvětví v EU27 vykazují jako celek růstovou tendenci, což je klíčový faktor pro hodnocení atraktivity trhu pro startupy.

Tabulka č. 4: Obrat dle odvětví mezi lety (tis. USD)

(Zdroj: vlastní zpracování)

		Obrat tis. USD v letech				
		2014	2015	2016	2017	2018
Odvětví	21	392 846 252	394 502 509	398 666 689	477 606 205	466 434 385
	26	435 510 268	442 574 017	462 287 300	532 294 765	548 451 479
	30.3	265 517 907	261 358 093	265 269 923	305 548 890	308 446 199
	Celkem	1 093 874 428	1 098 434 619	1 126 223 912	1 315 449 861	1 323 332 063

		Obrat tis. USD v letech				
		2019	2020	2021	2022	2023
Odvětví	21	493 392 084	577 618 025	575 849 538	620 323 591	649 271 861
	26	589 738 636	611 208 473	654 543 465	686 558 184	681 534 451
	30.3	327 593 987	258 077 172	244 636 403	274 932 766	289 161 825
	Celkem	1 410 724 707	1 446 903 670	1 475 029 406	1 581 814 541	1 619 968 136

Pro analýzu růstu odvětví byla využita databáze ORBIS Europe. Cílem bylo získat přehled o meziročním růstu obratu ve vybraných odvětvích high-tech sektoru v absolutních číslech, aby mohla být aproximována dynamika celého trhu. Tento přístup umožňuje posoudit celkový vývoj jednotlivých odvětví i celého high-tech sektoru v rámci EU27.

Aby byly získány co nejrelevantnější data, bylo aplikováno několik filtrů. Do analýzy byly zahrnuty pouze aktivní společnosti, což znamená, že byly v době sběru dat stále podnikatelsky činné. Tento filtr eliminuje zkrslení způsobené neaktivními nebo zaniklými firmami. V rámci právní formy byly zvoleny společnosti s ručením omezeným (s.r.o.) a akciové společnosti (a.s.), jelikož tyto typy podniků tvoří dominantní část podnikatelského prostředí v EU27 a jejich finanční výkazy jsou nejlépe dostupné a srovnatelné. Na rozdíl od vzorku pro prediktivní model, kde jsou analyzovány pouze malé a střední podniky, byly v této části ponechány všechny velikosti podniků. Tento krok byl zvolen proto, aby byl zajištěn co nejkomplexnější přehled o celém trhu.

Při výběru dat nebylo přihlíženo k vlastnictví firem ani k roku jejich založení. Zahrnutím všech společností bez ohledu na jejich vlastnickou strukturu nebo stáří bylo umožněno lépe reflektovat celkový tržní vývoj. Geograficky byla analýza omezena na země Evropské unie,

aby byla zachována konzistence s prediktivním modelem, který se rovněž soustředí na tento region.

Tabulka č. 5: Procentuální meziroční růst obrátu dle odvětví

(Zdroj: vlastní zpracování)

Procentuální meziroční růst obrátu						
		2015	2016	2017	2018	2019
Odvětví	21	0.42%	1.06%	19.80%	-2.34%	5.78%
	26	1.62%	4.45%	15.14%	3.04%	7.53%
	30.3	-1.57%	1.50%	15.18%	0.95%	6.21%
	Celkem	0.42%	2.53%	16.80%	0.60%	6.60%
Procentuální meziroční růst obrátu						
		2020	2021	2022	2023	Celkem
Odvětví	21	17.07%	-0.31%	7.72%	4.67%	65.27%
	26	3.64%	7.09%	4.89%	-0.73%	56.49%
	30.3	-21.22%	-5.21%	12.38%	5.18%	8.90%
	Celkem	2.56%	1.94%	7.24%	2.41%	48.09%

Při hodnocení procentního meziročního růstu obrátu (tabulka číslo 5) v odvětvích farmaceutického průmyslu, elektroniky a optiky a letectví mezi lety 2014–2023 lze pozorovat výrazné rozdíly v dynamice jednotlivých sektorů. Zatímco některá odvětví vykazovala stabilní a dlouhodobě rostoucí trend, jiná čelila značné volatilitě, zejména v souvislosti s globálními událostmi, jako byla pandemie COVID-19. Celkově vzrostl obrát těchto odvětví za sledované období o 48.09 %, přičemž nejvýraznější růst zaznamenal farmaceutický sektor, následovaný výrobou elektroniky a optiky, zatímco letecký průmysl vykázal nejnižší dynamiku.

Farmaceutický sektor byl v celém období nejstabilněji a nejrychleji rostoucím odvětvím s celkovým růstem 65.27 %. Do roku 2017 se růst pohyboval v relativně nízkých hodnotách, ale v roce 2017 zaznamenal prudký skok o 19.80 %. Následující rok 2018 přinesl mírné zpomalení o 2.34 %, které však bylo v roce 2019 kompenzováno opětovným růstem o 5.78 %. Výrazným zlomem se stal rok 2020, kdy sektor reagoval na pandemii COVID-19 prudkým nárůstem o 17.07 %, což lze přičíst extrémní poptávce po lécích a vakcínách. Po pandemickém šoku následovala stabilizace s mírným poklesem v roce 2021 o 0.31 %, což

mohlo být důsledkem normalizace trhu. V následujících dvou letech opět rostl, i když mírnějším tempem 7.72 % v roce 2022 a 4.67 % v roce 2023, což naznačuje pokračující investice do farmaceutického výzkumu a inovací.

Druhé nejsilnější odvětví z hlediska růstu byla výroba elektroniky a optických produktů, která za celé sledované období vzrostla o 56.49 %. Prvních několik let se neslo ve znamení postupného zrychlování, kdy růst v roce 2015 činil 1.62 %, ale již v roce 2017 dosáhl 15.14 %, což signalizovalo rostoucí poptávku po technologiích. Podobně jako farmaceutický průmysl zaznamenala elektronika v roce 2018 zpomalení růstu na 3.04 %, což ale neznamenalo dlouhodobý trend – v roce 2019 vzrostl sektor opět o 7.53 %. Pandemie v roce 2020 přinesla pokles růstu na 3.64 %, který se v roce 2021 dále zrychlil na 7.09 %, pravděpodobně díky zvýšené poptávce po elektronice v souvislosti s prací na dálku a digitalizací firem. V roce 2022 se růst udržel na 4.89 %, avšak rok 2023 přinesl mírný pokles o -0.73 %, což může souviset s přehřátím trhu a dočasným nasycením poptávky. Přesto se jedná o dlouhodobě silný sektor s vysokým inovačním potenciálem.

Největší volatilitu a nejslabší celkový růst – tedy 8.90 % vykazoval letecký a kosmický průmysl, který čelil několika zásadním krizím. Již v roce 2015 zaznamenal jako jediné odvětví pokles o 1.57 %, avšak v roce 2017 se situace výrazně změnila a růst dosáhl 15.18 %, což mohlo souviset s vysokou poptávkou po letecké dopravě a investicemi do vesmírného výzkumu. Od roku 2018 však nastalo opětovné zpomalení o 0.95 % v roce 2018 a o 6.21 % v roce 2019, které vyvrcholilo v roce 2020 dramatickým propadem o 21.22 %, kdy pandemie COVID-19 prakticky zastavila leteckou dopravu a způsobila globální krizi v celém odvětví. Navzdory poklesu se sektor od roku 2021 začal postupně zotavovat, i když byl stále v negativních číslech (-5.21 %), což značí dlouhodobější dopad pandemie. Teprve v roce 2022 došlo k viditelnému oživení a k růstu o 12.38 %, které pokračovalo i v roce 2023 (5.18 %), ale stále v nižším tempu než u ostatních odvětví. Tento sektor se sice zotavuje, ale jeho budoucnost je nejistá.

3. Popis analyzovaného vzorku a použitých metod

3.1. Analyzovaný vzorek

V rámci zpracování práce bylo klíčové zajistit relevantní a kvalitní data, která by umožnila provést přesnou analýzu. V následující části jsou popsány jednotlivé kroky a důvody, proč byla použita konkrétní kritéria výběru dat.

Pro sběr dat byla použita databáze ORBIS Europe, která poskytuje rozsáhlé ekonomické a finanční informace o společnostech v celé Evropě. ORBIS Europe je důvěryhodný zdroj pro získání dat o podnicích, přičemž nabízí detailní přehled o společnostech v různých odvětvích. Výhodou ORBIS Europe je možnost filtrování dle specifických kritérií, což umožňuje cílený výběr dat.

Pro zajištění relevantnosti dat bylo rozhodnuto o výběru pouze aktivních společností. Tato volba je důležitá, protože startupy, které jsou neaktivní nebo neexistují, by zkreslovaly výsledky analýzy, jelikož nebylo jako kritérium úspěšnosti společnosti vybráno to, jestli je či není aktivní eventuálně jestli zbankrotovala, ale úspěšnost byla stanovována na základě ziskovosti.

Jelikož je práce zaměřena na společnosti v high-tech sektoru, byly vybrány následující odvětví, která odpovídají klasifikaci podle NACE Rev. 2:

21 - Manufacture of basic pharmaceutical products and pharmaceutical preparations (Výroba základních farmaceutických výrobků a farmaceutických přípravků)

26 - Manufacture of computer, electronic and optical products (Výroba počítačů, elektronických a optických výrobků)

30.3 - Manufacture of air and spacecraft and related machinery (Výroba leteckých a kosmických lodí a souvisejících strojů a zařízení)

Tato odvětví byla zvolena na základě rozdělení vypracovaném společností Eurostat, ve kterém jsou konkrétně zmíněna pouze tato tři odvětví.

Jako oblast pro výběr společností byl zvolen prostor EU27, který zahrnuje všechny členské státy Evropské unie k roku 2025. Využití celé oblasti EU umožňuje širší srovnání mezi jednotlivými zeměmi. Vliv na úspěch společností je mimo jiné založený na rozdílech mezi jednotlivými státy. Tím, že státy dosahují rozdílných hodnot ve vybraných ukazatelích, může být pozorován jejich vliv na úspěch či neúspěch.

Byly zahrnuty pouze společnosti s právní formou s.r.o. (společnost s ručením omezeným) a a.s. (akciová společnost).

Byly vybrány jen nezávislé společnosti, tedy firmy, které nejsou dceřinými společnostmi větších korporací. Nezávislé společnosti lépe reprezentují startupy, protože obvykle nejsou přímo ovlivněny mateřskými společnostmi z hlediska kapitálových zdrojů, řízení nebo strategických rozhodnutí. Tento výběr zajišťuje, že analyzované subjekty skutečně čelí výzvam charakteristickým pro startupy.

Nakonec byly vybrány pouze malé a střední podniky, a to z důvodů uvedených v literární rešerši.

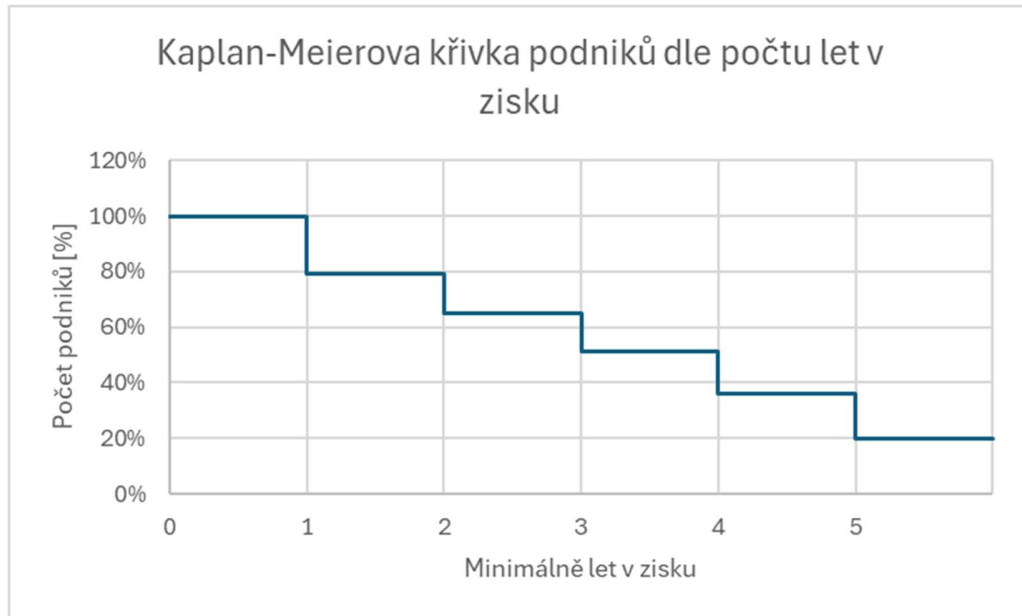
Na základě literární rešerše byla vybrána doba, po kterou je podnik nazýván startupem, pět let (ovšem za dodržení dalších podmínek). Pro identifikaci společností, které jsou v rané fázi svého vývoje, bylo vybráno období založení od roku 2014 do roku 2020. Toto období umožňuje zahrnout společnosti, které jsou v prvních pěti letech své existence, což je typicky období kdy společnosti čelí velkým výzvam, protože nejsou ještě „zaběhnuté“ a musí si pojistit své místo na trhu. Do tohoto výběru spadají sice i společnosti, které fungují již delší dobu, nicméně u všech společností byly ve všech případech brány pouze data za prvních pět let.

Základní soubor, po aplikování všech těchto pravidel, čítal 999 společností, u kterých bylo zveřejněno dostatečné množství dat pro analýzu navrhovaných prediktorů.

3.1.1. Kaplan-Meierova křivka dosahování zisku

Tato kapitola se zaměřuje na analýzu podílu podniků v high-tech sektoru, které byly v zisku alespoň určitý počet let během prvních pěti let po založení (graf číslo 1). Pro analýzu byla

využita data zmíněných 999 podniků, přičemž pro každý podnik byl zaznamenán počet let, během nichž byl v zisku. Data byla následně transformována do kumulativní podoby, která umožňuje určit podíl podniků, které dosáhly zisku alespoň v X letech.



Graf č. 1: Kaplan-Meierova křivka podniků dle počtu let v zisku

(Zdroj: vlastní zpracování)

Přibližně 79 % podniků bylo ziskových alespoň 1 rok. 51 % podniků bylo ziskových alespoň 3 roky a pouze 19,8 % podniků dosáhlo zisku ve všech 5 letech. Většina podniků se alespoň jednou dostane do zisku, pouze asi polovina podniků dokáže v rané fázi podnikání zisk udržet „dlouhodobě“. Přibližně 20 % podniků nikdy nedosáhne zisku, což ukazuje vysoké riziko podnikání. Tento graf ukazuje, že zvolený počet let v zisku (3), aby byl podnik klasifikovaný v této práci v rámci analýzy jako úspěšný, rozděluje analyzovaný vzorek přibližně na polovinu. To by mělo zajistit lepší schopnost modelu správně predikovat jak úspěšné, tak neúspěšné podniky.

3.2. Metodika predikce

Z důvodů uvedených v literární rešerši bylo v této práci jako kritérium úspěchu startupu zvoleno dosažení zisku. Důvodem není ziskovost sama, ale fakt, že ziskové startupy mají až desetkrát vyšší míru přežití než ty neziskové. Konkrétně bylo rozhodnuto, že startup je považován za úspěšný, pokud splňuje následující podmínku: dokázal dosáhnout zisku alespoň ve třech z pěti prvních let svého působení. Tento přístup zohledňuje možnou fluktuaci ziskovosti v počátečních fázích podnikání. Z vybraného vzorku dat o velikosti 999 společností vyšlo tímto způsobem 512 úspěšných podniků.

Hodnota prediktorů růst vlastního kapitálu, růst obratu a růst pracovního kapitálu byla brána za čtvrtý rok od založení podniku. U hodnot prediktorů HDP na obyvatele, míra nezaměstnanosti, index EDB, existence dceřiné společnosti a běžná likvidita byl postup rozdílný – zde byla brána data za rok předcházející úspěchu, tak jak byl definován. U prediktoru růstu odvětví byla brána data za pět let zpětně od roku předcházejícímu roku úspěchu.

Několik společností nezveřejňovalo veškerá data, která byla pro analýzu potřebná. Proto byly chybějící hodnoty nahrazeny průměrem.

Na začátku analytické části bude provedena popisná statistika, která slouží k úvodnímu zhodnocení datového souboru a k základnímu srovnání úspěšných a neúspěšných startupů. Cílem je identifikovat hlavní rozdíly mezi těmito dvěma skupinami a odhalit případné charakteristiky, které by mohly predikovat úspěch či neúspěch. Popisná statistika bude zahrnovat výpočet základních charakteristik, jako je průměr, medián a směrodatná odchylka pro úspěšné a neúspěšné startupy zvlášť a pro každou proměnnou zvlášť.

Pro ověření vztahu mezi vybranými prediktory a pravděpodobností dosažení úspěchu startupu bude použita metoda binární logistické regrese. Modely budou v programu RStudio odhadnuty pomocí funkce `glm()`, s použitím binomického rozdělení (`family = binomial`). Tento přístup bude zvolen vzhledem k binární povaze závislé proměnné (v tomto případě je každé jedné společnosti přiřazeno buď číslo 1 (úspěšný podnik) nebo číslo 0 (neúspěšný podnik)), což umožní odhad pravděpodobnosti zařadit do jedné ze dvou kategorií. Logistická

regrese dále umožní interpretaci prediktorů prostřednictvím odhadů regresních koeficientů a jejich statistických významností.

Všechny statistické testy budou prováděny na hladině významnosti $\alpha = 0.05$. Výsledky testů a odhady parametrů budou doplněny o intervaly spolehlivosti tam, kde to bude relevantní, s cílem poskytnout co nejúplnější informace o přesnosti a stabilitě odhadů.

Obecný model logistické regrese je vyjádřen následovně:

$$\text{logit}(p) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \quad (1)$$

Zdroj: Vlastní zpracování dle: Řeháková, 2000

Kde:

p – je pravděpodobnost závislé proměnné

β_0 – je intercept (počáteční hodnota)

$\beta_1, \beta_2, \dots, \beta_k$ – jsou koeficienty regresních parametrů

x_0, x_1, \dots, x_k – jsou nezávislé proměnné (faktory, které mohou ovlivnit výstup)

Nicméně pro jednorozměrné testování bude použit vzorec zjednodušený, který je odvozen od vzorce obecného a je pouze ve tvaru:

$$\text{logit}(p) = \beta_0 + \beta_1 x_1 \quad (2)$$

Zdroj: Vlastní zpracování dle: Řeháková, 2000

Analýza bude probíhat ve dvou hlavních fázích: nejprve bude provedeno jednorozměrné testování, které umožní posoudit vliv jednotlivých prediktorů samostatně, a následně bude provedeno vícerozměrné testování, které umožní zhodnotit jejich kombinovaný vliv a vytvořit predikční model.

Před vlastní tvorbou modelu bude tedy provedena analýza jednotlivých prediktorů za účelem posouzení jejich vlivů na úspěch a posouzení prediktivních schopností jednoduchých modelů z těchto prediktorů vycházejících. V rámci jednorozměrného testování bude každý prediktor analyzován krom logistické regrese i pomocí ROC analýzy, která je podrobněji popsána níže.

U každého prediktoru bude posouzena jeho statistická významnost a bude určena jeho diskriminační schopnost pomocí plošné pod ROC křivkou (AUC).

V kapitole popisující výsledky jednorozměrného testování budou pro analyzované prediktory shrnuty hodnoty interceptu (β_0), hodnoty regresního koeficientu daného prediktoru (β_1) spolu s jejich exponovanými hodnotami a p-hodnoty.

Intercept neboli absolutní člen v logistické regresi představuje základní pravděpodobnost úspěchu startupu v případě, že všechny prediktory mají hodnotu nula. Regresní koeficient vyjadřuje směr a velikost vlivu daného prediktoru na úspěch startupu. Kladná hodnota regresního koeficientu znamená, že zvýšení hodnoty prediktoru zvyšuje pravděpodobnost úspěchu. Naopak u záporné hodnoty regresního koeficientu zvýšení hodnoty prediktoru snižuje pravděpodobnost úspěchu.

Matematicky je tento vztah popsán vzorcem 2. Tento vzorec vychází z logaritmu poměru pravděpodobnosti a jejího doplňku. Vzorec lze zapsat v následujícím tvaru:

$$\text{logit}(p) = \ln\left(\frac{p}{1-p}\right) \quad (3)$$

Zdroj: Vlastní zpracování dle: Řeháková, 2000

Tento vztah je třeba následně převést na pravděpodobnost úspěchu, kterou model startupu skutečně přisuzuje. To lze provést pomocí inverzní logistické funkce:

$$p = \frac{1}{1+e^{-(\beta_0+\beta_1x_1)}} \quad (4)$$

Zdroj: Vlastní zpracování dle: Řeháková, 2000

Exponenciální transformace regresního koeficientu představuje poměr šancí na úspěch při zvýšení prediktoru o jednotku (někdy také jako „odds ratio“). Pokud je hodnota exponovaného regresního koeficientu větší než 1 znamená to, že vyšší hodnota prediktoru zvyšuje pravděpodobnost úspěchu. Například pokud $e\beta_1 = 1.5$, znamená to, že při zvýšení prediktoru o jednotku se šance na úspěch zvýší 1.5krát. Pokud je hodnota naopak menší než 1 znamená to, že vyšší hodnota prediktoru snižuje pravděpodobnost úspěchu. Například pokud $e\beta_1 = 0.7$, znamená to, že při zvýšení prediktoru o jednotku se šance na úspěch sníží

na 70 % původní hodnoty. Pokud je hodnota rovna 1, znamená to, že prediktor nemá žádný vliv na pravděpodobnost úspěchu.

P-hodnota ukazuje, zda je vliv daného prediktoru statisticky významný nebo ne. Jak již bylo napsáno, hladina významnosti α byla stanovena pro tuto práci ve výši 0.05. Proto pokud bude p-hodnota vyšší nebo rovna 0.05, nebude prediktor vnímán jako statisticky významný. Pokud však bude hodnota p daného prediktoru nižší než 0.05, lze pak prediktor považovat za statisticky významný na hladině významnosti 5 % – existuje tedy méně než 5% pravděpodobnost, že pozorovaný efekt vznikl náhodou.

Nízká p-hodnota potvrzuje, že prediktor je důležitý pro prediktivní model. Nicméně i prediktory, které vykážou v jednorozměrném testování vyšší p-hodnotu, mohou mít význam ve vícerozměrném modelu, protože jejich kombinace s jinými proměnnými může zvýšit celkovou predikční schopnost modelu.

K vyhodnocení výkonu modelů budou použity různé metody, které umožňují posoudit schopnost modelu správně rozlišovat mezi úspěšnými a neúspěšnými startupy.

Nástrojem pro zhodnocení predikční schopnosti modelu je v první řadě matice záměn (confusion matrix), která zobrazuje správnost predikce modelu na základě skutečných výsledků. Tato matice poskytuje konkrétní přehled o počtu správně (1) a nesprávně (0) klasifikovaných případů, což umožňuje vypočítat základní ukazatele, jako je přesnost modelu, specifita a senzitivita. Pomocí těchto hodnot lze získat představu o tom, jak dobře model funguje v reálných podmínkách a jak spolehlivě je schopen identifikovat úspěšné či neúspěšné startupy.

U matice záměn je potřeba stanovit tzv. cut-off neboli prahovou hodnotu. Cut-off představuje hranici pravděpodobnosti v intervalu od 0 do 1, od které je pozorovaná hodnota vnímána jako úspěšná či neúspěšná. Pro jednorozměrné testování bude hodnota cut-off stanovena na 0.5, jelikož i kdyby byla výše prahové hodnoty optimalizována tak, aby modely poskytovaly co nejpřesnější predikce, pro komplexní model by tato zjištění nepřinášela dodatečný benefit. Optimalizace tak bude provedena až u komplexního modelu.

Další důležitou metodou pro hodnocení predikční schopnosti modelu je ROC křivka (Receiver Operating Characteristic curve), která zobrazuje vztah mezi senzitivitou (true positive rate) – tedy schopností správně identifikovat úspěšné podniky a specifitou (true negative rate) – tedy schopností správně identifikovat neúspěšné podniky. Z této křivky lze získat hodnotu Area Under Curve (AUC), která představuje plochu pod ROC křivkou a která poskytuje celkové zhodnocení výkonnosti modelu. Hodnoty AUC umožňují klasifikovat modely podle jejich schopnosti rozlišovat do několika pásem:

Pokud AUC nabývá hodnoty 0.5, znamená to, že nemá žádnou rozlišovací schopnost – model nerozpozná úspěšné a neúspěšné startupy, což značí, že model se chová podobně jako náhoda.

Hodnota od 0.5 do 0.7 značí slabou rozlišovací schopnost – model má nízkou schopnost správně odhadnout úspěch či neúspěch startupů.

U hodnot od 0.7 do 0.8 již model vykazuje dobrou schopnost rozlišovat mezi úspěšnými a neúspěšnými startupy a je použitelný.

Modely s vynikající schopností rozlišení dosahují hodnoty AUC od 0.8 do 0.9 a od této horní hranice se již jedná o modely s výjimečně silnou schopností rozlišovat mezi úspěchem a neúspěchem (či jinou závislou proměnnou).

Pro každý model bude kromě hodnoty AUC stanovena i statistická významnost této hodnoty pomocí DeLongova testu, který bude nastaven tak, aby ověřil, zda je dosažená p-hodnota vyšší nebo nižší než hladina významnosti α , a tedy zdali je hodnota AUC na této hladině významnosti statisticky odlišná od 0.5 (tedy od náhodné predikce).

Předpokladem této analýzy je, že jednotlivé prediktory samy o sobě nebudou mít vysokou schopnost predikce, neboť úspěch startupu nezáleží na jediném faktoru, ale spíše na jejich kombinaci. Tento přístup je obdobný jako u bankrotních modelů, které rovněž nevycházejí z izolovaných ukazatelů, ale z jejich vzájemných vztahů. Proto bude důležité nejen posoudit individuální predikční sílu jednotlivých faktorů, ale i jejich souhrnný vliv v rámci vícerozměrného modelu.

Následně bude sestavena tabulka zachycující korelační koeficienty pro zjištění případné multikolinearity. Korelační analýza je klíčovým krokem v procesu modelování, zejména když se pracuje s více prediktory, které mohou být vzájemně provázány. V rámci analýzy bude nezbytné ověřit, zda mezi zvolenými prediktory neexistuje nadměrná vzájemná korelace, která by mohla ovlivnit kvalitu modelu. Tento problém, jinak jako multikolinearita, může mít negativní dopad na spolehlivost odhadů koeficientů v regresních modelech, což následně komplikuje interpretaci a predikci.

Multikolinearita nastává, když jsou dva nebo více prediktorů v modelu silně korelované, což může způsobit několik problémů. Za prvé, silně korelované prediktory mohou způsobit, že odhady koeficientů se stanou nestabilními – i malé změny v datech mohou vést k velkým změnám ve výsledných hodnotách koeficientů. Za druhé, v přítomnosti multikolinearity je obtížné pochopit, jaký vliv má každý jednotlivý prediktor na závislou proměnnou, protože se efekty několika proměnných mohou vzájemně kompenzovat. A za třetí, vysoká korelace mezi prediktory může vést k tomu, že model je zbytečně složitý a má nižší schopnost generalizace na nová data.

Korelační analýza poskytne přehled o vztazích mezi prediktory. Pokud se ukáže, že mezi prediktory existují silné korelace, bude nutné vyloučit ty prediktory, které nepřinášejí nové, nezávislé informace.

Po provedení jednorozměrných analýz jednotlivých prediktorů, zhodnocení jejich vztahů s úspěšností startupů a zhodnocení korelační analýzy bude přistoupeno k vícerozměrnému modelování. Cílem této fáze analýzy je vytvořit predikční model, který by zohledňoval současně všechny relevantní faktory a umožnil tak přesnější odhad pravděpodobnosti úspěchu startupu.

Vícerozměrný model bude sestaven za použití všech navržených proměnných, přičemž pro optimalizaci modelu bude následně využita metoda zpětné eliminace (stepwise backward selection). Tento přístup spočívá v postupném odebírání proměnných z modelu a umožní identifikaci nejdůležitějších faktorů, které nejvíce přispívají k vysvětlení pravděpodobnosti úspěchu. Následně budou z modelu odebrány i prediktory, které nemají statistickou významnost.

Metoda zpětné eliminace začíná s kompletním modelem zahrnujícím všechny prediktory a v každém kroku odstraňuje tu proměnnou, jejíž vyřazení nejvíce přispívá ke zlepšení modelu podle hodnoty Akaikeho informačního kritéria (AIC). AIC je ukazatel kvality modelu, přičemž nižší hodnota AIC znamená lepší kompromis mezi přesností modelu a jeho složitostí. Cílem této procedury je dosáhnout co nejnižší hodnoty AIC.

Stabilita a možnost zobecnění modelu bude ověřena pomocí metody křížové validace, konkrétně desetinásobné (10-fold) křížové validace. Tento postup bude spočívat v opakovaném dělení dat na trénovací a validační sady, což umožní získat robustní odhad predikční schopnosti modelu a současně odhalit případné přeučení modelu na trénovací data. Výsledky jednotlivých validací budou shrnuty průměrnou hodnotou AUC.

Tento postup spočívá v náhodném rozdělení dat do deseti přibližně stejně velkých částí, přičemž v každém kroku je model trénován na devíti foldech (částech) a testován na zbývajícím. Tento proces se opakuje desetkrát tak, aby byl každý fold použit právě jednou jako testovací sada. Výsledkem je soubor deseti odhadů výkonnosti modelu, které umožňují posoudit jeho stabilitu napříč různými podmnožinami dat.

Součástí této části práce bude rovněž vyhodnocení predikční schopnosti vícerozměrného modelu. Stanovení optimální hodnoty rozhodovacího prahu (cut-off) bude stanovena pomocí Youdenova indexu, aby byl maximalizován součet senzitivity a specificity tedy celé prediktivní schopnosti modelu.

V závěrečné části práce bude vyčíslen praktický příklad na konkrétních vstupech (hodnotách jednotlivých proměnných) modelu. Tento příklad ukáže, jak může predikce úspěchu konkrétního startupu vypadat.

4. Vlastní návrh modelu predikce a jeho ověření

Cílem této kapitoly je provést statistickou analýzu faktorů ovlivňujících úspěch high-tech startupů v zemích EU27.

4.1. Popisná statistika

Tabulka č. 6: Popisná statistika neúspěšných startupů

(Zdroj: vlastní zpracování)

	HDP	Nezaměstnanost	EDB	Dceřiná společnost	Růst odvětví	Růst VK	Růst obratu	Běžná likvidita	Pracovní kapitál
Průměr	30 515	6.16%	76.52	0.04	17.48%	419%	1 948%	0.54	190%
Medián	29 200	5.80%	76.30	0	18.23%	-5%	56%	1.00	-20%
Směr. odch.	7 264	2.71%	3.43	0.19	8.88%	4 118%	8 022%	0.50	6 839%

Tabulka č. 7: Popisná statistika úspěšných startupů

(Zdroj: vlastní zpracování)

	HDP	Nezaměstnanost	EDB	Dceřiná společnost	Růst odvětví	Růst VK	Růst obratu	Běžná likvidita	Pracovní kapitál
Průměr	26 583	7.16%	74.91	0.05	19.99%	919%	1 262%	0.82	518%
Medián	26 200	6.70%	73.60	0	22.22%	179%	249%	1.00	40%
Směr. odch.	5 502	3.04%	2.51	0.22	7.76%	4 591%	3 717%	0.39	4 587%

Popisná statistika poskytla základní přehled o charakteristikách úspěšných a neúspěšných startupů v rámci analyzovaného vzorku. Výsledky ukázaly zajímavé rozdíly mezi těmito skupinami.

Průměrná hodnota HDP na obyvatele v zemích, kde sídlí neúspěšné startupy, činila přibližně 30 515 USD, zatímco u úspěšných startupů byla tato hodnota nižší, přibližně 26 583 USD. Mediánové hodnoty ukazují podobný trend, přičemž u neúspěšných startupů dosahuje 29 200 EUR a u úspěšných 26 200 EUR. Tento rozdíl naznačuje, že úspěšné startupy se často nacházejí v ekonomikách s nižším HDP na obyvatele.

Lehký rozdíl lze pozorovat i u míry nezaměstnanosti, kde je průměrná hodnota i medián u úspěšných startupů vyšší než u neúspěšných.

I u indexu snadnosti podnikání byly pozorovány drobné rozdíly. Jak průměrná hodnota, tak medián indexu EDB je u úspěšných startupů nižší než u těch neúspěšných.

Podíl startupů s dceřinou společností je u úspěšných i neúspěšných téměř stejný. Tento faktor tedy podle popisné statistiky nemá významný rozdíl mezi skupinami.

Růst vlastního kapitálu vykazuje u úspěšných startupů výrazně vyšší průměr oproti neúspěšným. Medián růstu VK je rovněž vyšší u úspěšných než u neúspěšných (kde je dokonce záporný), což ukazuje na pozitivní korelaci růstu vlastního kapitálu s úspěšností. Zajímavé je, že směrodatná odchylka je v obou skupinách velmi vysoká, což ukazuje na značnou variabilitu mezi jednotlivými startupy.

Tato skutečně obrovská variabilita dat mezi jednotlivými podniky je patrná u prediktorů, které zachycují růst některé podnikově specifické veličiny (vlastní kapitál a obrat) či podnikově specifického finančního ukazatele (čistý pracovní kapitál). Je to způsobeno tím, že podniky v datasetu mají v prvním roce existence často vlastní kapitál, obrat či čistý pracovní kapitál v řádu jednotek tisíc USD nebo téměř nulové. Naopak ve čtvrtém roce existence mají tyto podniky nezdědka kdy tyto hodnoty v řádu stovek tisíc až milionů USD. Tyto turbulentní růsty nemusí být pro startupy neobvyklé.

Průměr růstu obratu je naopak vyšší u neúspěšných startupů. Tento jev může být vysvětlen tak, že některé neúspěšné startupy zaznamenaly prudký růst, který však nebyl udržitelný. Medián růstu obratu u úspěšných firem je však podstatně vyšší než u neúspěšných, což naznačuje, že stabilnější a vyváženější růst přináší vyšší pravděpodobnost dlouhodobého úspěchu.

Běžné likvidity vyšší než 1 dosáhlo podstatně více úspěšných startupů (konkrétně o 28 p. b. více). Tento výsledek naznačuje, že schopnost pokrývat krátkodobé závazky je důležitým faktorem pro úspěch startupu.

V oblasti růstu pracovního kapitálu jsou rozdíly ještě výraznější. Průměrná hodnota růstu u úspěšných startupů činí 518 %, zatímco u neúspěšných pouze 190 %. Mediánový rozdíl je rovněž značný, kde u neúspěšných podniků je dokonce záporný. Tento rozdíl ukazuje, že pracovní kapitál je klíčová proměnná pro úspěch startupů.

Pro další analýzu bude vhodné zaměřit se na to, jak a do jaké míry ovlivňují rozdíly mezi úspěšnými a neúspěšnými podniky pravděpodobnost úspěchu.

4.2. Výsledky jednorozměrného testování vlivu prediktorů

Výstupy modelů poskytly několik klíčových parametrů, které umožnily lépe porozumět vlivu těchto prediktorů na pravděpodobnost úspěchu startupu. Výsledky analýzy jsou shrnuty v tabulkách 8 a 9, které obsahují několik klíčových statistik. Konkrétně pak hodnotu interceptu (β_0), hodnotu regresního koeficientu daného prediktoru (β_1), jejich exponované hodnoty a nakonec p-hodnotu. V druhé tabulce jsou uvedeny 95% intervaly spolehlivosti.

Tabulka č. 8: Jednorozměrné testování

(Zdroj: vlastní zpracování)

Prediktor	Intercept (β_0)	Beta (β_1)	Exp(Intercept)	Exp(Beta1)	P-hodnota
HDP na obyvatele	2.980	$-1,033 \times 10^{-4}$	19.669	0.999	$<2 \times 10^{-16}$
Míra nezaměstnanosti	- 0.752	0.121	0.471	1.128	1.170×10^{-7}
EDB index	14.262	- 0.188	1.562×10^6	0.829	7.040×10^{-15}
Dceřiná společnost	0.034	0.372	1.034	1.451	0.232
Růst odvětví	- 0.670	3.809	0.512	45.082	8.190×10^{-6}
Růst VK	0.046	8.258×10^{-4}	1.047	1.001	0.080
Růst obratu	0.052	-9.982×10^{-7}	1.053	0.999	0.757
Běžná likvidita	- 0.884	1.353	0.413	3.869	$<2 \times 10^{-16}$
Růst WC	- 0.087	1.079×10^{-3}	0.916	1.001	9.710×10^{-9}

Tabulka č. 9: jednorozměrné testování – intervaly spolehlivosti

(Zdroj: vlastní zpracování)

Prediktor	2.50%	97.50%
HDP na obyvatele	0.99987	0.99992
Míra nezaměstnanosti	1.07965	1.18072
EDB index	0.78900	0.86800
Dceřiná společnost	0.79405	2.71118
Růst odvětví	8.93241	256.69088
Růst VK	1.00012	1.00195
Růst obratu	0.99999	1.00001
Běžná likvidita	2.91315	5.17121
Růst WC	1.00072	1.00146

Nejprve byla zkoumána souvislost mezi **HDP na obyvatele** a úspěšností startupu. HDP na obyvatele byl zahrnut jako jeden z hlavních prediktorů, přičemž záměrem bylo zjistit, jaký vliv má ekonomická vyspělost státu na pravděpodobnost úspěchu společnosti v prvních letech její existence. Výsledky ukázaly, že HDP na obyvatele má statisticky významný vliv na úspěch startupu, přičemž tento vliv je negativní, což znamená, že s rostoucím HDP na obyvatele klesá pravděpodobnost úspěchu startupu.

P-hodnota pro tento prediktor byla velmi nízká, což znamená, že výsledky jsou statisticky významné. To potvrzuje, že HDP na obyvatele má reálný vliv na úspěch startupů a tento vliv nelze považovat za náhodný. Vzhledem k tomu, že p-hodnota byla výrazně pod stanovenou hladinou významnosti (0.05), můžeme s vysokou jistotou říci, že tento efekt je reálný a relevantní pro analýzu úspěchu startupů.

Koeficient pro HDP na obyvatele byl negativní, což naznačuje, že existuje inverzní vztah mezi HDP na obyvatele a pravděpodobností úspěchu startupu. I když se tento vztah jeví jako velmi malý (což naznačuje i velikost koeficientu), je důležité si uvědomit, že i malé změny v HDP mohou mít významný dopad, zvláště v kontextu ekonomické variability mezi státy. V tomto případě platí, že každé zvýšení HDP na obyvatele o jednu jednotku (v tomto případě o 1 USD) snižuje pravděpodobnost úspěchu startupu o velmi malou hodnotu, nicméně tento efekt se kumulativně projevuje při větších změnách HDP.

Rozptyl hodnot HDP mezi státy je značný, přičemž v datasetu se hodnoty pohybovaly mezi 15 000 a 85 000 USD na obyvatele. Pro lepší pochopení, jak změna HDP na obyvatele ovlivní pravděpodobnost úspěchu startupu, byla provedena simulace, jak se pravděpodobnost změní při změně HDP na obyvatele o 1000 USD. Při výpočtu bylo vycházeno z následujícího vzorce:

$$\Delta P = 1 - (\exp(\beta_1))^{\Delta x} \quad (5)$$

Po dosazení příslušných hodnot byla získána změna pravděpodobnosti:

$$\Delta P = 1 - 0.9998967^{1000} \approx 0.0981 \quad (6)$$

Tento výpočet ukazuje, že při zvýšení HDP na obyvatele o 1 000 USD dojde ke změně pravděpodobnosti úspěchu startupu přibližně o 9.81 %. To znamená, že při zvýšení HDP na obyvatele o 1000 USD se pravděpodobnost úspěchu startupu sníží o zhruba 9.81 %.

Pro posouzení přesnosti odhadu koeficientu HDP na obyvatele byl rovněž spočten 95% interval spolehlivosti pro jeho exponovanou hodnotu. Jelikož celý interval leží pod hodnotou 1, potvrzuje to negativní vliv HDP na pravděpodobnost úspěchu startupu. Jinými slovy, i po zohlednění statistické nejistoty platí, že vyšší HDP na obyvatele systematicky snižuje pravděpodobnost, že bude startup úspěšný.

V další fázi analýzy byl hodnocen vliv **míry nezaměstnanosti** na pravděpodobnost úspěchu startupu. Cílem bylo zjistit, zda vyšší nebo nižší míra nezaměstnanosti v dané zemi souvisí s lepšími podmínkami pro rozvoj nově vznikajících společností. Nezaměstnanost byla zvolena jako jeden z klíčových makroekonomických ukazatelů, který může ovlivnit chování potenciálních zakladatelů startupů kvůli aktuální dostupnosti a ceně pracovních sil ve společnosti.

Výsledky regresního modelu ukázaly, že míra nezaměstnanosti má statisticky významný a pozitivní vliv na úspěch startupů. P-hodnota pro tento prediktor byla velmi nízká, což svědčí o vysoké statistické významnosti výsledku. Můžeme tedy s vysokou mírou jistoty tvrdit, že vztah mezi nezaměstnaností a úspěchem startupů není náhodný.

Koeficient pro nezaměstnanost byl pozitivní, což znamená, že se zvyšující se mírou nezaměstnanosti roste pravděpodobnost, že startup bude úspěšný. Tento výsledek může být interpretován tak, že nejspíš bude snazší a levnější získávat lidské zdroje, jelikož jich bude více k dispozici.

Exponovaný koeficient pro nezaměstnanost vyšel na 1.128, což znamená, že při zvýšení míry nezaměstnanosti o 1 procentní bod se šance na úspěch startupu zvýší přibližně o 12.8 %.

Aby byl tento vztah lépe pochopen, byla provedena simulace, jak se změní pravděpodobnost úspěchu startupu při zvýšení míry nezaměstnanosti o 2 procentní body. Výpočet vychází ze vzorce 5, kde je po dosazení patřičných hodnot získáno následující:

$$\Delta P = 1 - 1,128^2 \approx -0.272 \quad (7)$$

To znamená, že zvýšení míry nezaměstnanosti o 2 procentní body zvyšuje pravděpodobnost úspěchu startupu přibližně o 27.2 %.

Důležitým ukazatelem je také interval spolehlivosti pro tento exponovaný prediktor. S 95% pravděpodobností se skutečný vliv nezaměstnanosti na šanci startupu na úspěch nachází mezi 1.080 a 1.181. Jelikož je celý interval nad hodnotou 1, lze tento vliv považovat za statisticky významně pozitivní.

Jedním z klíčových faktorů, které by mohly ovlivnit úspěšnost startupů, je ekonomické prostředí a administrativní náročnost, ve kterém společnosti operují. Pro zhodnocení této problematiky byl zkoumán vliv **indexu snadnosti podnikání (Ease of Doing Business Index, EDB)** na pravděpodobnost úspěchu společností v jednotlivých státech Evropské unie. Index EDB je komplexním ukazatelem, který hodnotí, jak snadné je v určitém státě zahájit a provozovat podnikání. Vyšší hodnota indexu zpravidla znamená příznivější prostředí pro provoz podnikání.

Výsledky regresní analýzy ukázaly, že EDB má statisticky významný vliv na úspěch startupů. Tento vliv je však negativní, což znamená, že s rostoucí hodnotou indexu snadnosti podnikání se pravděpodobnost úspěchu startupu snižuje. Jinými slovy, startupy, které vznikají v prostředí, kde je podnikání administrativně jednodušší, mají paradoxně nižší šanci na úspěch.

P-hodnota pro index EDB byla velmi nízká, což znamená, že výsledky jsou statisticky významné a nelze je považovat za náhodné. Každé zvýšení indexu EDB o jednu jednotku snižuje šanci na úspěch startupu o přibližně 17.14 % ($1-0.8286$).

Tato data jsou ale velmi silně zkreslená. Výše indexu se pro evropské země pohybuje ve většině případech mezi hodnotami 70 a 80. Model tvrdí, že pokud by byl index roven nule byla by šance na úspěch 1562359:1 (podle výše exponovaného interceptu), což je nutno chápat jako nutnost modelu nikoli situaci, která může reálně nastat. Je to z důvodu, že index nikdy nedosahuje nulové hodnoty. Významnějším důvodem je to, že data jsou pouze ze zemí Evropské unie. Model stanovil určitý trend, který do jisté míry vysvětloval úspěch či

neúspěch v EU. Ale kdyby se tvořil dle dat z jiných regionů, ve kterých jsou diametrálně rozdílné socioekonomické poměry, vypadal by jinak.

Pro posouzení přesnosti odhadu koeficientu indexu EDB byl také spočítán 95% interval spolehlivosti pro exponovanou hodnotu. Tento interval leží celý pod hodnotou 1, což potvrzuje, že změna EDB skutečně snižuje pravděpodobnost úspěchu startupu. I po zohlednění statistické nejistoty platí, že vyšší hodnoty EDB snižují pravděpodobnost, že startup bude úspěšný.

Tato zjištění poukazují na to, že příznivější podnikatelské prostředí nemusí vždy zaručit úspěch startupu. V zemích s vysokými hodnotami indexu EDB může být konkurence silná, kvůli čemu může být pro nově vznikající firmy složitější prosadit se na trhu.

Tato zjištění poukazují na to, že i přes očekávání, že příznivější podnikatelské prostředí bude mít pozitivní vliv na úspěch startupů, tato data ukázala ve skutečnosti trend opačný.

V této části analýzy byl zkoumán vliv **existence dceřiné společnosti** na úspěch startupu. Proměnná označující, zda má startup dceřinou společnost, byla vyjádřena binárně (0 = nemá, 1 = má) a byla zahrnuta do modelu za účelem ověření hypotézy, že startupy, které mají dceřinou společnost, mohou být úspěšnější díky lepší finanční situaci nebo organizační struktuře.

Vliv existence dceřiné společnosti nebyl statisticky významný. Přestože odhadovaný efekt byl pozitivní, nelze jej s dostatečnou statistickou jistotou považovat za průkazný. Tento výsledek je ovlivněn tím, že většina startupů v datovém souboru dceřinou společnost neměla, což mohlo ovlivnit robustnost výsledku.

Další skutečností, která mluví proti praktické využitelnosti tohoto prediktoru je rozsah 95% intervalu spolehlivosti. Tento interval zahrnuje hodnotu 1, což znamená, že se nelze s jistotou domnívat, že existence dceřiné společnosti zvyšuje nebo snižuje šanci na úspěch. V některých případech může být vliv dokonce mírně negativní.

Jedním z klíčových faktorů ovlivňujících pravděpodobnost úspěchu startupu se v této analýze stal **růst odvětví**, ve kterém startup působí. Tato proměnná byla definována jako růst obratu celého odvětví mezi rokem před rokem dosažení úspěchu a čtvrtým rokem zpětně od toho

momentu. Takový přístup umožnil zahrnout do modelu makroekonomický kontext a zachytit tržní dynamiku, která mohla ovlivnit šance jednotlivých podniků na úspěch.

Logistická regrese ukázala velmi silný a jednoznačný vztah mezi tempem růstu odvětví a pravděpodobností úspěchu startupu. Výše koeficientu β naznačuje výrazný pozitivní vliv. Po převedení na exponenciální škálu je tento koeficient ve výši 45.08, tedy každé zvýšení růstu odvětví o jednotku zvyšuje šanci startupu na úspěch přibližně 45krát. K takové situaci však zpravidla docházet nebude. Jednotka v tomto případě totiž znamená 100%.

Aby bylo možné tento vztah interpretovat v reálnějších podmínkách, byla provedena simulace, jak by se změnila pravděpodobnost úspěchu startupu při zvýšení růstu odvětví o 5 %. Výpočet vychází ze vzorce 5, kde po dosažení získáme následující hodnotu:

$$\Delta P = 1 - 45.08^{0.05} \approx -0.2097 \quad (8)$$

Tedy, zvýšení růstu odvětví o 5 % zvyšuje pravděpodobnost úspěchu startupu přibližně o asi 21 %.

Dolní hranice 95% intervalu spolehlivosti činí 8.93, což znamená, že i v nejméně příznivém scénáři může nárůst růstu odvětví o 100 % zvýšit šance startupu na úspěch téměř devítinásobně. Horní hranice intervalu byla odhadnuta na 256.69, což dokládá potenciální sílu tohoto faktoru v extrémně příznivých podmínkách. Jak již bylo řečeno, tyto hodnoty jsou málo reálné, jelikož ke 100% růstu dojde jen zřídka a ve sledovaném vzorku k takovému růstu nedošlo. Tím pádem není model na podobné případy „trénovaný“.

Z hlediska statistické významnosti je vliv růstu odvětví na úspěch startupů vysoce průkazný. Hodnota p je výrazně nižší než hladina významnosti, což potvrzuje, že růst odvětví hraje klíčovou roli při vysvětlování úspěšnosti startupů. Tento výsledek je konzistentní s teoretickými očekáváními, že dynamicky se rozvíjející trhy nabízejí lepší podmínky pro růst nových firem.

Výsledek tak potvrzuje předpoklad, že startupy působící v rychle rostoucích sektorech mají znatelně vyšší šanci na dosažení úspěchu. Růst odvětví se z tohoto pohledu jeví jako jeden z nejvýznamnějších faktorů v rámci modelu.

Růst vlastního kapitálu startupu mezi prvním a čtvrtým rokem může být klíčovým ukazatelem pro jeho dlouhodobý úspěch. Tento prediktor odráží schopnost startupu přitahovat investice nebo generovat zisk, což může zásadně ovlivnit jeho finanční stabilitu a možnosti růstu

Vliv změny vlastního kapitálu mezi 1. a 4. rokem na úspěch startupu je pozitivní, ale velmi slabý. Nárůst vlastního kapitálu pravděpodobnost úspěchu startupu zvýší pouze minimálně.

P-hodnota je jen lehce vyšší než 0.05 (0.08), což ukazuje, že i když není tento faktor v obvyklých statistických testech považován za významný, může mít stále slabý, ale potenciálně důležitý vliv na úspěch startupu.

Důležité je také zhodnotit 95% interval spolehlivosti. Dolní hranice (1.0001160) a horní hranice (1.001952) ukazují, že i v rámci intervalu spolehlivosti hodnoty exponovaného koeficientu je změna vlastního kapitálu ve všech případech stále pozitivní. Její vliv na úspěch startupu je velmi malý, ale reálný. Je možné, že v souvislosti s ostatními prediktory bude změna vlastního kapitálu zlepšovat prediktivní schopnost celkového modelu. Toto bude ověřeno dále v práci.

Mezi často sledované ekonomické ukazatele výkonnosti firem patří **vývoj obratu** v čase, který může odrážet růst firmy. V této části byl proto analyzován vliv změny výše obratu mezi prvním a čtvrtým rokem fungování startupu. Cílem bylo zjistit, zda může být dynamika obratu v počátečním období považována za prediktor budoucí úspěšnosti.

Výsledky logistické regresní analýzy ukázaly, že proměnná nemá žádný významný vliv na úspěch startupu. Výše koeficientu regresního modelu indikuje extrémně malý negativní vztah. Exponovaná hodnota koeficientu ukazuje, že zvýšení obratu o 1 jednotku snížilo šanci na úspěch startupu jen zcela nepatrně – vliv, který je prakticky zanedbatelný.

Interval spolehlivosti pro exponovanou betu těsně obklopuje hodnotu 1. Tím je potvrzeno, že vztah mezi změnou obratu a úspěchem není statisticky významný ani po zohlednění statistické nejistoty. Jinými slovy, růst či pokles obratu mezi 1. a 4. rokem od založení nelze považovat za spolehlivý indikátor toho, zda startup bude úspěšný.

P-hodnota pro tento prediktor je výrazně nad obvyklou hladinou statistické významnosti. Změna obratu tedy není statisticky významným prediktorem.

Následně je analyzován vliv **běžné likvidity** na pravděpodobnost úspěchu. Proměnná byla definována jako binární – hodnoty 1 bylo dosaženo v případě, že startup měl běžnou likviditu ≥ 1 ; v opačném případě byla proměnná rovna 0.

Bylo zjištěno, že proměnná má statisticky významný a silně pozitivní vliv na pravděpodobnost úspěchu startupu. Bylo zjištěno, že startupům, které dosáhly běžné likvidity ≥ 1 , je připisována téměř čtyřikrát vyšší šance na úspěch oproti těm, které této hodnoty nedosáhly.

Statistická významnost tohoto vztahu byla potvrzena extrémně nízkou p-hodnotou, což svědčí o tom, že pravděpodobnost, že byl tento výsledek získán náhodou, je prakticky nulová. Výsledky tak mohou být považovány za velmi signifikantní.

Po transformaci interceptu na exponovanou hodnotu lze konstatovat, že poměr šancí (odds ratio) na úspěch pro startupy bez dosažené likvidity ≥ 1 je přibližně 41 %. Samotné dosažení likvidity ≥ 1 pak zvyšuje šanci na úspěch velmi výrazně. Aby mohlo být zjištěno, do jaké míry dosažení požadované likvidity působí na úspěch a neúspěch, může být vypočítána konkrétní pravděpodobnost po dosažení do vzorce 2 (logistický model o jedné proměnné). Nejprve bude do vzorce dosazen intercept a koeficient β .

$$\text{logit}(p) = -0.8835 + 1.353 \cdot x_1 \quad (9)$$

Nyní je možné na místo x_1 dosadit hodnoty 0 resp. 1 a následně dosadit do vzorce 4 (vzorec pro zpětnou transformaci logitu na pravděpodobnost) pro zjištění pravděpodobnosti úspěchu podniků s likviditou nižší než 1 resp. podniků s likviditou vyšší nebo rovnou 1. Pro $x_1 = 0$ vypadá výpočet následovně:

$$\text{logit}(p) = -0.8835 + 1.353 \cdot 0 \quad (10)$$

$$\text{logit}(p) = -0.8835 \quad (11)$$

Nyní je možné dosadit výši logitu do inverzní logistické funkce a vypočítat pravděpodobnost úspěchu startupů s nedostatečnou likviditou.

$$p = \frac{1}{1+e^{-(-0.8835)}} \quad (12)$$

$$p = \frac{1}{1+e^{0.8835}} \quad (13)$$

$$p \approx 0.2925 \quad (14)$$

V následujícím kroku bude obdobně vypočtena pravděpodobnost úspěchu i pro podniky s likviditou vyšší nebo rovno 1.

$$\text{logit}(p) = -0.8835 + 1.353 \cdot 1 \quad (15)$$

$$\text{logit}(p) = 0.4695 \quad (16)$$

Zde bude opět logit dosazen do inverzní logistické funkce, díky čemuž může být poté vypočítána pravděpodobnost úspěchu startupů s dostatečnou likviditou.

$$p = \frac{1}{1+e^{-(0.4695)}} \quad (17)$$

$$p \approx 0.6153 \quad (18)$$

Výsledky logistické regrese ukazují, že dosažení běžné likvidity alespoň 1 má výrazný vliv na pravděpodobnost úspěchu startupu. Pro startupy, které dosáhly běžné likvidity nižší než 1, model predikuje pravděpodobnost úspěchu přibližně 29 %. Tento výsledek naznačuje, že startupy, které nejsou schopny pokrýt své krátkodobé závazky, mají podstatně nižší šanci na úspěch.

Na druhé straně, startupům s dosaženou požadovanou běžnou likviditou model přiřazuje pravděpodobnost úspěchu 61.5 %. To znamená, že startupy, které mají dostatečnou likviditu k pokrytí svých závazků, mají více než dvojnásobnou pravděpodobnost úspěchu oproti těm bez likvidity. Tento rozdíl v pravděpodobnostech podtrhuje klíčovou roli likvidity jako prediktoru úspěchu startupu.

Startupy, které mají dostatek prostředků k pokrytí svých krátkodobých závazků, jsou výrazně více chráněny před riziky, která mohou vést k jejich neúspěchu.

Pro odhadnutý koeficient tohoto prediktoru byl dále vypočten 95% interval spolehlivosti pro exponovanou hodnotu, který vyšel v rozsahu 2.91 až 5.17. Jelikož celý interval leží výrazně nad hodnotou 1, je možné s vysokou mírou jistoty potvrdit, že dosažení běžné likvidity významně zvyšuje pravděpodobnost úspěchu. I po zohlednění statistické nejistoty platí, že likvidita hraje klíčovou roli v predikci úspěchu startupu.

Tato zjištění potvrzují, že schopnost startupu krátkodobě krýt své závazky je pro jeho úspěch zásadní. Finančně stabilnější podniky mohou působit důvěryhodněji vůči investorům, obchodním partnerům i zaměstnancům. Zároveň lze předpokládat, že dosažením dostatečné likvidity je odrážena schopnost startupu lépe plánovat a řídit cashflow.

Jedním z analyzovaných faktorů, který může potenciálně ovlivňovat úspěšnost startupů, je **změna pracovního kapitálu**. Tato změna byla měřena mezi prvním a čtvrtým rokem.

Logistická regrese ukázala, že změna pracovního kapitálu má statisticky významný pozitivní vliv na pravděpodobnost úspěchu startupu. Výše β koeficientu značí, že s každou jednotkovou změnou pracovního kapitálu roste pravděpodobnost úspěchu startupu, i když samotný efekt je velmi malý.

Exponovaná hodnota koeficientu ukazuje, že každé zvýšení pracovního kapitálu o 1 jednotku – tedy o 100 % oproti výchozímu stavu – zvyšuje šanci na úspěch startupu přibližně o 0.1079 %. Přestože se tento efekt může zdát marginální, je důležité jej chápat v kontextu analyzovaného souboru. V mnoha případech byl totiž mezi prvním a čtvrtým rokem provozu zaznamenán nárůst pracovního kapitálu o stovky, a někdy i tisíce procent.

Statistická významnost tohoto vztahu p a 95% interval spolehlivosti zároveň naznačují, že se jedná o skutečný, opakovatelný jev a nikoli náhodný výkyv v rámci analyzovaného vzorku. I přes malou hodnotu efektu v jednotkovém vyjádření tak změna pracovního kapitálu představuje relevantní faktor, jehož vliv by neměl být v predikčním modelování opomíjen.

4.3. Zhodnocení predikční síly a vlivu prediktorů na úspěch v jednorozměrném testování

V této kapitole je podrobně zhodnocena predikční síla modelů a vliv jednotlivých prediktorů na pravděpodobnost úspěchu startupů. V této části je také popsáno, do jaké míry je možné pouze za použití jednoho konkrétního prediktoru odhadovat úspěšnost. Je potřeba poznamenat, že úspěch, dle toho, jak je definován, nikdy nezáleží pouze na jednom nebo několika málo faktorech. Proto nelze očekávat nikterak vysokou predikční schopnost těchto jednorozměrných modelů. Nicméně pokud budou jejich AUC hodnoty větší než 0.5 (například kolem 0.6 či vyšší), může to být vnímáno jako náznak toho, že díky takovému prediktoru bude pak komplexní model schopen přesnějších predikcí.

V tabulce číslo 10 jsou uvedeny hodnoty AUC jednotlivých modelů a p-hodnoty těchto hodnot AUC.

Tabulka č. 10: AUC hodnoty jednorozměrných modelů a jejich statistická významnost

(Zdroj: vlastní zpracování)

Prediktor	AUC	p-hodnota
HDP na obyvatele	0.6609	0.0032
Míra nezaměstnanosti	0.5957	0.0185
EDB index	0.646	0.0027
Dceřiná společnost	0.5079	0.6241
Růst odvětví	0.6088	0.0121
Růst VK	0.6564	0.0019
Růst obratu	0.5094	0.5876
Běžná likvidita	0.6402	0.0039
Růst WC	0.463	0.1427

Pro zjištění predikční síly modelu zachycujícího vliv výše **HDP na obyvatele** na úspěch startupu byla vytvořena confusion matrix (matice záměn) (tabulka číslo 11). Hodnota 0 zachycuje v matici neúspěšné startupy a hodnota 1 zachycuje úspěšné startupy. Model správně predikoval 326 úspěšných startupů a 249 neúspěšných, což celkově představuje


přesnost modelu 57.56 %. Model dokáže více spolehlivě odhadovat úspěšné společnosti a to z 57.8 %.

Tabulka č. 11: Confusion matrix (predikce úspěšnosti podle výše HDP na obyvatele)

(Zdroj: vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	249	238
Predikce 1	186	326

Pro posouzení predikční schopnosti modelu byla použita ROC křivka (graf č. 2) a hodnota Area under curve. Hodnota AUC naznačuje, že model má sám o sobě sice slabou schopnost rozlišovat mezi úspěšnými a neúspěšnými startupy. Nicméně jelikož se jedná pouze o vliv faktoru vnějšího prostředí, ve kterém se startupy nachází, je tato hodnota poměrně dosti vysoká a pro finální model bude tento prediktor představovat významné zpřesnění prediktivní schopnosti. P-hodnota pro AUC poukazuje na statistickou významnost této hodnoty. Odlišnost této AUC hodnoty od náhodné predikce je tedy statisticky významná.



Graf č. 2: ROC křivka – HDP na obyvatele

(Zdroj: vlastní zpracování)

Z výsledků analýzy vyplývá, že HDP na obyvatele má statisticky významný, ale relativně slabý vliv na úspěšnost startupů, když se však vezme v potaz velký rozptyl výše HDP na osobu, může mít tento parametr už poměrně velký celkový vliv na úspěch či neúspěch. S rostoucím HDP pravděpodobnost úspěchu mírně klesá. Je patrné, že samotná hodnota HDP na obyvatele není dostatečně silným faktorem pro přesnou predikci úspěchu startupu.

Vliv změny HDP na obyvatele o velké částky naznačuje, že startupy ve státech s vyšším HDP mohou mít nižší pravděpodobnost úspěchu, což by mohlo být vysvětleno větší konkurencí nebo složitějšími podmínkami vstupu na trh. Tento výsledek je přesně opačný oproti předpokladu stanovenému v literární rešerši.

Pro zjištění predikční síly modelu založeného na **míře nezaměstnanosti** byla vytvořena matice záměn (tabulka 12). Model správně predikoval 280 úspěšných startupů a 272


neúspěšných, což celkově představuje přesnost modelu 55.26 %. Model byl o něco úspěšnější v predikci neúspěšných společností.

Tabulka č. 12: Confusion matrix (predikce úspěšnosti podle míry nezaměstnanosti)

(Zdroj: Vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	272	232
Predikce 1	215	280

Pro posouzení predikční schopnosti modelu byla opět využita ROC křivka (graf 3) a hodnota AUC. Výše hodnoty AUC značí, že model má jen mírně lepší prediktivní schopnost než náhodný tip rozlišovat mezi úspěšnými a neúspěšnými startupy. V kontextu toho, že se opět jedná pouze o jeden externí makroekonomický ukazatel, však tato hodnota není zanedbatelná. Je možné, že v kombinaci s dalšími prediktory bude přínos tohoto faktoru znatelnější. P-hodnota pro AUC naznačuje, že výsledek je na hladině statistické významnosti odlišný od náhodné predikce.



Graf č. 3: ROC křivka – Míra nezaměstnanosti

(Zdroj: vlastní zpracování)

Z výsledků predikční analýzy vyplývá, že ačkoliv má míra nezaměstnanosti statisticky významný vztah k úspěchu startupů, její samotná predikční síla je poměrně nízká. Model založený pouze na tomto jednom ukazateli nedokáže dostatečně spolehlivě rozlišit mezi úspěšnými a neúspěšnými podniky. Hodnota AUC jen těsně překračuje hranici náhodné predikce a celková přesnost klasifikace nepřekračuje 56 %.

Je proto zřejmé, že samotná míra nezaměstnanosti nemůže sloužit jako spolehlivý prediktor úspěchu startupu. Její přínos však nespočívá v izolované predikci, ale spíše ve vstupu do komplexnějšího modelu, kde se bude kombinovat s dalšími faktory. V tomto může pozitivní vztah mezi mírou nezaměstnanosti a úspěšností startupů znamenat, že vyšší nezaměstnanost zvyšuje ochotu lidí zakládat vlastní podnikání, nebo že startupy těží z levnější pracovní síly a nižší konkurence na trhu práce. Tento výsledek potvrzuje první ze dvou předpokladů stanovených v literární rešerši. Zjištění autorů Holmese, Hunta a Stona (2008) se těmito výpočty nepotvrdilo.

Pro hodnocení predikční síly modelu, který zkoumal vliv **indexu snadnosti podnikání** (EDB) na úspěch startupů, byla opět vytvořena matice záměn (tabulka 13).

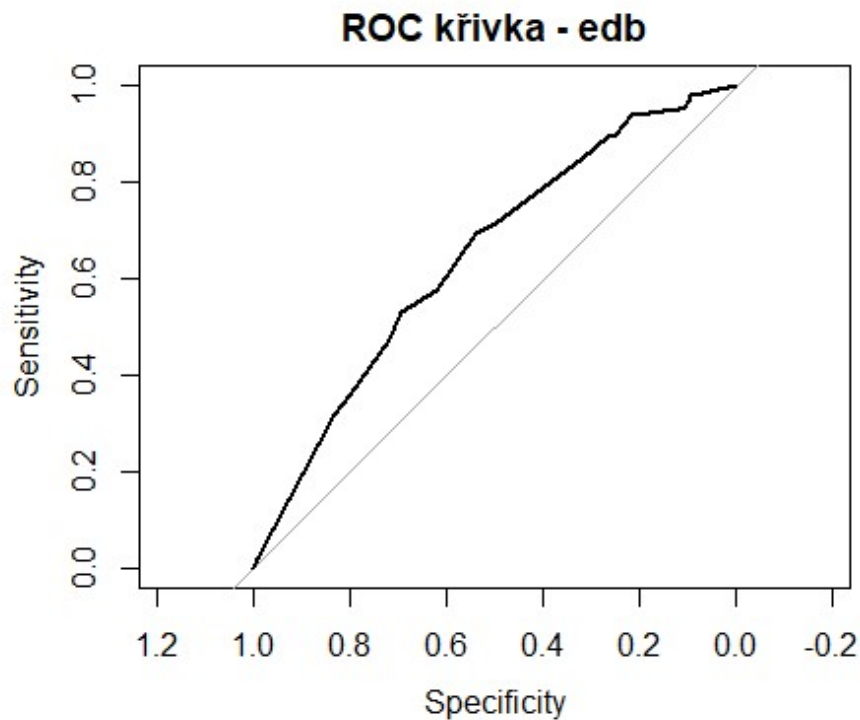
Tabulka č. 13: Confusion matrix (predikce úspěšnosti podle hodnoty indexu snadnosti podnikání)

(Zdroj: Vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	262	225
Predikce 1	157	355

Z této matice je patrné, že model správně predikoval 262 neúspěšných startupů a 355 úspěšných startupů. Celková přesnost modelu dosáhla hodnoty 61.76 %. Tento výsledek je na model o jedné proměnné poměrně dobrý.

Pro detailní vyhodnocení výkonu modelu byla vytvořena ROC křivka (graf 4) a vypočtena hodnota AUC. Výše této hodnoty opět ukazuje na slabou, ovšem nezanedbatelnou, schopnost modelu rozlišovat mezi úspěšnými a neúspěšnými startupy. Dále byla spočítána p-hodnota pro AUC, která potvrzuje, že predikční síla modelu je statisticky významná, a dá se tvrdit, že se statisticky liší od náhodného výběru.



Graf č. 4: ROC křivka – Index EDB

(Zdroj: vlastní zpracování)

Výsledky analýzy ukazují, že index snadnosti podnikání má statisticky významný vliv na úspěch startupů, přičemž tento vliv je negativní. Vyšší hodnoty indexu EDB, které obvykle ukazují na příznivější podnikatelské prostředí, jsou spojeny s nižší pravděpodobností úspěchu startupu. Tento jev je v rozporu s očekávanými výsledky, tak jak byly předpokládány v rámci literární rešerše.

Pro posouzení predikční síly modelu zachycujícího binární proměnnou „**existence dceřiné společnosti**“ byla vypočtena AUC hodnota, jejíž výše značí prakticky nulovou schopnost modelu rozlišovat mezi úspěšnými a neúspěšnými startupy. Tato hodnota je velmi blízká náhodnému odhadu (0.5). Navíc i p-hodnota pro AUC potvrdila, že predikční schopnost tohoto modelu není statisticky významná.

Růst je podle literatury jedním z klíčových faktorů pro úspěch startupů. Proto je dalším z analyzovaných prediktorů **míra růstu odvětví**.

Pro zjištění predikční schopnosti modelu byla opět využita matice záměn (tabulka 14). Model správně predikoval 366 úspěšných startupů a 233 neúspěšných, což znamená celkovou přesnost modelu 59.96 %. Model tedy vykazuje mírnou (nicméně slabou) schopnost správně identifikovat úspěšné startupy.

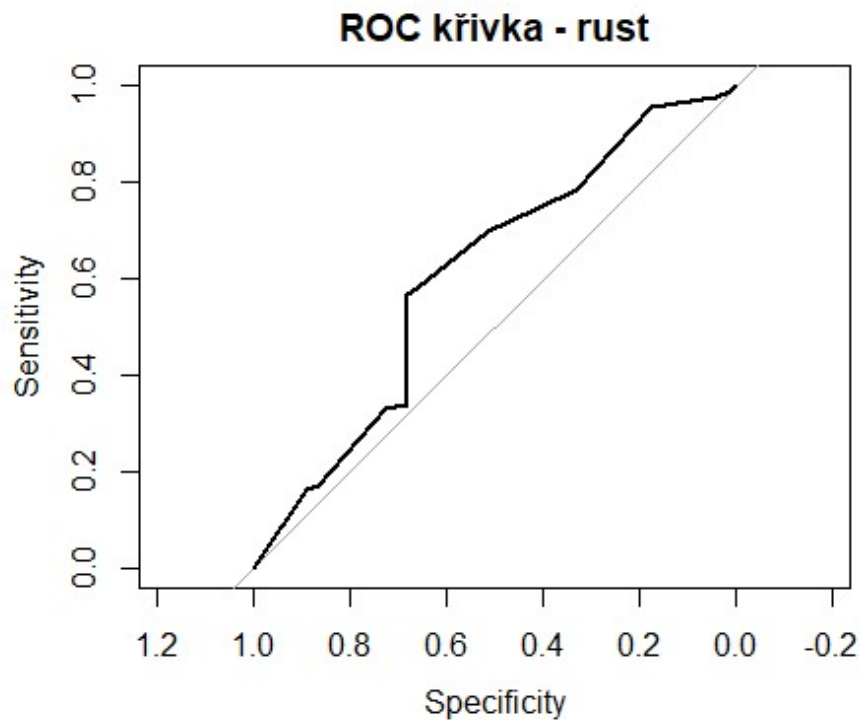
Tabulka č. 14: Confusion matrix (predikce úspěšnosti podle míry růstu odvětví)

(Zdroj: Vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	233	254
Predikce 1	146	366

Pro posouzení predikční schopnosti modelu byla opět použita ROC křivka (graf 5) a hodnota AUC. Hodnota AUC pro růst odvětví ukazuje, že model má slabou, ale nezanedbatelnou predikční schopnost při rozlišování mezi úspěšnými a neúspěšnými startupy. Tento výsledek je poměrně významný – růst odvětví má vcelku silný vliv na úspěch startupu. P-hodnota pro AUC byla <0.05 , což znamená, že model není náhodný a má prediktivní schopnosti, a tedy růst odvětví je statisticky významným faktorem pro úspěch startupu.

To, že bude mít růst v rámci odvětví pozitivní vliv na úspěch, bylo již předpokládáno v literární rešerši. Toto tvrzení se také potvrdilo.



Graf č. 5: ROC křivka – Růst odvětví

(Zdroj: vlastní zpracování)


Pro zjištění predikční schopnosti modelu založeného na **změně vlastního kapitálu** mezi 1. a 4. rokem od založení startupu byla vytvořena matice záměn (tabulka 15). Model správně predikoval 15 neúspěšných startupů a 506 úspěšných startupů, což celkově představuje přesnost modelu na úrovni 55.79 %. Model má velmi zřetelný problém s nadhodnocováním společností, jelikož jich valnou většinu označil jako úspěšné. Matice byla počítána s několika prahovými hodnotami (0.4, 0.5, 0.6), nicméně pokaždé vracela predikci, která byla nakloněna na jednu nebo na druhou stranu.

Tabulka č. 15: Confusion matrix (predikce úspěšnosti podle změny vlastního kapitálu)

(Zdroj: Vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	15	472
Predikce 1	6	506

Dále byla sestavena ROC křivka (graf 6) a vyčíslena hodnota AUC. Hodnota AUC naznačuje, že model má mírně lepší schopnost rozlišovat mezi úspěšnými a neúspěšnými startupy. Hodnota AUC u toho prediktoru je nejvyšší ze všech analyzovaných prediktorů. V kombinaci s dalšími prediktory by mohl být tento faktor cenný pro predikci úspěchu startupů. P-hodnota pro AUC potvrzuje, že výsledek je statisticky významný.



Graf č. 6: ROC křivka – Změna vlastního kapitálu

(Zdroj: vlastní zpracování)

Z výsledků analýzy vyplývá, že změna vlastního kapitálu má statisticky významný, ale pouze slabý vliv na úspěšnost startupu. Model založený pouze na této proměnné nemá dostatečnou predikční sílu k přesnému rozlišení mezi úspěšnými a neúspěšnými startupy. Přesto ukazuje, že pokud se vlastní kapitál startupu během prvních čtyř let významně zvyšuje, může to být indikátor pro vyšší pravděpodobnost úspěchu, což odpovídá předpokladu stanovenému úvodní části práce.

Pro zhodnocení prediktivní schopnosti logistického modelu založeného na procentuální **změně obratu** byla nejprve sestavena matice záměn (tabulka 16). Z ní vyplynulo, že bylo správně klasifikováno 510 úspěšných startupů a 3 neúspěšné, zatímco 484 neúspěšných bylo modelem označeno jako úspěšné a 2 úspěšné jako neúspěšné. Celková přesnost klasifikace modelu tak činila 51.35 %. Z tohoto výsledku je zřejmé, že model má tendenci označovat téměř všechny podniky jako úspěšné. Celková úspěšnost klasifikace se pohybuje na úrovni náhodného odhadu.

Tabulka č. 16: Confusion matrix (predikce úspěšnosti podle změny obratu)


(Zdroj: Vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	3	484
Predikce 1	2	510

Pro posouzení diskriminační schopnosti byl využit princip ROC křivky (graf 7) a vypočtena hodnota. Tato hodnota je téměř totožná s 0.5, která odpovídá náhodné klasifikaci, a naznačuje, že model nedokáže rozlišit mezi úspěšnými a neúspěšnými startupy lépe než pouhý odhad. P-hodnota testu AUC byla >0.05 , takže ještě k tomu nelze AUC hodnotu vnímat ani jako statisticky významnou.

Z výše uvedených hodnot je patrné, že prediktivní síla jednorozměrného modelu založeného výhradně na změně obratu mezi 1. a 4. rokem je velmi nízká. Závěrem je, že změna obratu v tomto období není dostatečným prediktorem úspěchu startupu. I tak bude prediktor testován v rámci vícerozměrného testování, nicméně na základě těchto dat je nepravděpodobné, že by měl být tento prediktor ve finálním modelu schopen pomoci k dosahování lepších výsledků predikce.

Tvrzení o pozitivním vlivu tohoto prediktoru na úspěch stanovené v literární rešerši se tímto nepotvrdilo.



Graf č. 7: ROC křivka – Změna výše obratu

(Zdroj: vlastní zpracování)

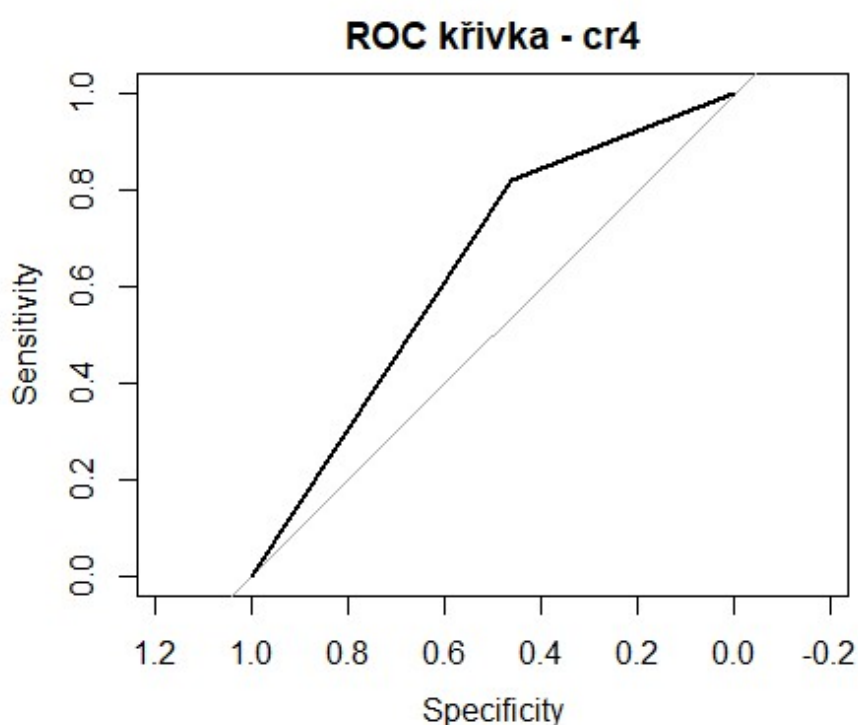
Pro zjištění predikční síly modelu, který odhaduje pravděpodobnost úspěchu startupu na základě **dosazení běžné likvidity ≥ 1** , byla vytvořena matice záměn (tabulka 17). Model správně predikoval 419 úspěšných startupů a 225 neúspěšných, což celkově představuje přesnost modelu 64.46 %. Model vykázal lepší schopnost predikovat úspěšné startupy, což může být signálem, že likvidita má silný vliv na úspěch startupu. Model byl velmi úspěšný u predikce neúspěšných startupů, kterých dokázal „odhalit“ více než 70 %. Nicméně u úspěšných startupů byl poměr správně predikovaných podniků vcelku nižší a to asi 62 %. I přesto lze konstatovat, že jelikož se jedná o jediný prediktor, je úspěšnost poměrně vysoká.

Tabulka č. 17: Confusion matrix (predikce úspěšnosti podle běžné likvidity)

(Zdroj: Vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	225	262
Predikce 1	93	419

Pro posouzení predikční schopnosti modelu byla použita ROC křivka (graf 8) a vypočtena hodnota AUC. Hodnota AUC značí, že model má slabší až střední predikční sílu, tedy je schopen rozlišit mezi startupy s dostatečnou a nedostatečnou likviditou s lepší než náhodnou přesností. Ačkoliv hodnota AUC není ideální, stále potvrzuje schopnost modelu odhadnout pravděpodobnost úspěchu startupů na základě jejich likvidity. P-hodnota pro AUC byla <0.05 , což naznačuje, že výsledek je na hladině statistické významnosti rozdílný od náhodného výběru.



Graf č. 8: ROC křivka – Běžná likvidita

(Zdroj: vlastní zpracování)

Uvedená ROC křivka má poměrně netradiční tvar. Pokud má binární model, který dává pouze dvě možné predikce (0 nebo 1), může to způsobit, že ROC křivka nebude plynulá. V podstatě se křivka v tomto případě může „zaseknout“ v několika bodech a vytvořit zlomené úseky.

Tento jev se může vyskytnout, pokud model neprodukuje pravděpodobnosti, ale spíše konečné rozhodnutí (0 nebo 1) na základě nějakého prahu, jak je to v tomto případě.

Celková přesnost modelu je slušná a je pravděpodobné, že kombinace tohoto prediktoru s dalšími faktory pomůže zlepšit celkovou schopnost predikce. Tento výsledek podtrhuje důležitost likvidity jako klíčového prediktoru úspěchu.

V literární rešerši byl stanoven předpoklad, že s dostatečnou likviditou bude mít společnost větší šanci na úspěch, což analýza jasně potvrzuje.

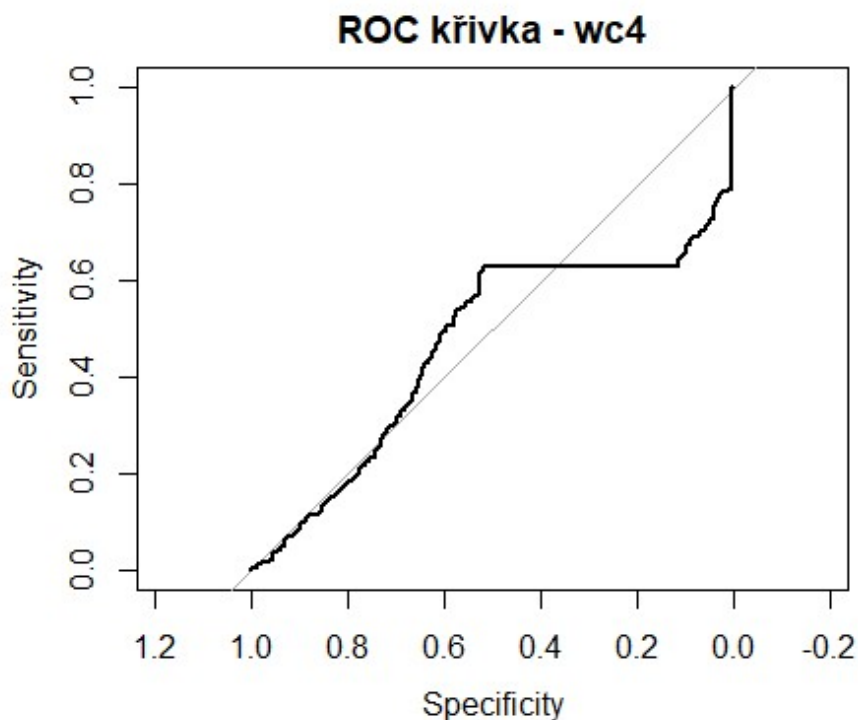
Pro zjištění predikční síly modelu založeného na **změně pracovního kapitálu** mezi prvním a čtvrtým rokem existence startupu byla vytvořena matice záměn (tabulka 18). Model správně predikoval 468 neúspěšných a 123 úspěšných startupů, což odpovídá celkové přesnosti 59.16 %. Model byl výrazně přesnější v predikci neúspěšných startupů.

Tabulka č. 18: Confusion matrix (predikce úspěšnosti podle změny pracovního kapitálu)

(Zdroj: Vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	225	262
Predikce 1	93	419

Pro posouzení predikční schopnosti modelu byla opět využita ROC křivka (graf 9) a hodnota AUC. Hodnota AUC pro tento model byla velmi nízká – konkrétně mírně pod úroveň náhodné predikce. Tento výsledek je překvapující zejména s ohledem na vysokou statistickou významnost samotného koeficientu v regresním modelu.



Graf č. 9: ROC křivka – Změna pracovního kapitálu

(Zdroj: vlastní zpracování)

Tento rozpor mezi vysokou statistickou významností a nízkou AUC může být dán několika faktory. Jedním z nich je nerovnoměrné rozložení hodnot pracovního kapitálu v datovém souboru – mnoho firem vykazovalo extrémní nárůsty (či extrémní propady) v řádu stovek, tisíců ale také klidně až desetitisíců procent, zatímco jiné téměř žádnou změnu. V takových případech může mít model problém s rozlišením mezi úspěšnými a neúspěšnými firmami při použití standardního prahu (cut-off 0.5), což se odrazí právě na nízké hodnotě AUC.

Z výše uvedeného vyplývá, že ačkoliv je změna pracovního kapitálu statisticky významným ukazatelem, jeho samostatná predikční síla je nedostatečná. Z toho důvodu může být užitečnější jako součást komplexnějšího predikčního modelu, kde jeho efekt v kombinaci s dalšími faktory přispěje k celkové přesnosti a výpovědní hodnotě modelu.

Teorie tvrdí, že růst pracovního kapitálu by měl přinášet růst šancí na úspěch. Z analyzovaných dat přesně tento vztah vyplývá.

4.4. Kontrola korelace

Z následující tabulky 19 je možné vidět výši korelací mezi jednotlivými prediktory:

Tabulka č. 19: Korelace mezi analyzovanými prediktory

(Zdroj: vlastní zpracování)

	HDP	Nezaměstnanost	EDB	Dceřiná společnost	Růst odvětví	Růst VK	Růst obratu	Běžná likvidita	Pracovní kapitál
HDP	1	0.117	0.460	0.023	-0.114	0.009	0.023	-0.023	0.013
Nezaměstnanost	0.117	1	-0.183	-0.003	0.1	0.013	0.071	0.105	0.065
EDB	0.4600	-0.183	1	-0.058	-0.028	0.024	-0.058	-0.022	0.023
Dceřiná spol.	0.023	-0.003	-0.058	1	0.051	0.007	-0.015	-0.028	-0.007
Růst odvětví	-0.114	0.1	-0.028	0.051	1	0.01	0.018	0.041	0.028
Růst VK	0.009	0.013	0.024	0.007	0.01	1	0.002	-0.021	0.002
Růst obratu	0.023	0.071	-0.058	-0.015	0.018	0.002	1	0.029	-0.002
Běžná likvidita	-0.023	0.105	-0.022	-0.028	0.041	-0.021	0.029	1	0.024
Prac. kapitál	0.013	0.065	0.023	-0.007	0.028	0.002	-0.002	0.024	1

Analýza byla provedena pomocí Pearsonova korelačního koeficientu, který měří sílu a směr lineárního vztahu mezi dvěma spojitými proměnnými. Koeficient korelace se pohybuje v rozmezí od -1 (perfektní negativní korelace) do +1 (perfektní pozitivní korelace), přičemž hodnota 0 znamená žádnou korelaci. Korelace vyšší, resp. nižší než 0.8 resp. -0.8, je již nutná řešit.

Výsledky korelační analýzy ukazují, že většina prediktorů mezi sebou vykazují slabou – maximálně střední korelaci. Například korelace mezi HDP na obyvatele a nezaměstnaností je pouze 0.117, což ukazuje na slabý pozitivní vztah mezi těmito dvěma ekonomickými faktory. Korelace mezi HDP na obyvatele a indexem EDB dosahuje hodnoty 0.460, což je střední pozitivní korelace, která naznačuje, že země s vyšším HDP na obyvatele mají obvykle lepší podmínky pro podnikání, což se projevuje i v lepším koeficientu snadnosti podnikání (EDB). Tento vztah však není dostatečně silný na to, aby to znamenalo problém s multikolinearitou.

Vzhledem k nízké korelaci mezi většinou proměnných lze pokračovat k vícerozměrnému testování, aniž by bylo nutné upravovat prediktory na základě multikolinearity.

4.5. Výsledky vícerozměrného testování

V této kapitole budou prezentovány výsledky vícerozměrné logistické regrese. Nejprve bude uvedena tabulka, která shrnuje základní parametry modelu (tabulka 20) – koeficienty s jejich exponenty a p-hodnoty pro jednotlivé prediktory. Následně bude provedena interpretace významných změn u jednotlivých prediktorů z hlediska jejich síly, směru a statistické významnosti efektu na úspěšnost startupu.

Tabulka č. 20: Vícerozměrné testování

(Zdroj: vlastní zpracování)

Proměnná	Beta (β)	Exp(Beta)	P-hodnota
(Intercept)	8.523	5 029.119	$1,500 \times 10^{-4}$
HDP na obyvatele	$-1,088 \times 10^{-4}$	0.9998	4.400×10^{-13}
Míra nezaměstnanosti	0.140	1.149	4.400×10^{-7}
EDB index	-0.106	0.899	5.620×10^{-4}
Dceřiná společnost	0.449	1.567	0.221
Růst odvětví	2.617	13.695	5.328×10^{-3}
Růst VK	3.712×10^{-4}	1.0004	0.386
Růst obratu	-3.933×10^{-6}	0.999996	0.255
Běžná likvidita	1.420	4.133	$<2 \times 10^{-16}$
Růst WC	1.242×10^{-3}	1.0012	1.200×10^{-8}

4.5.1. Porovnání dat jednorozměrného a vícerozměrného testování

Porovnáním výsledků jednorozměrného a vícerozměrného testování byly zaznamenány některé změny ve vlivu prediktorů na pravděpodobnost úspěchu startupu a v jejich statistické významnosti. Nicméně u většiny prediktorů významné změny zaregistrovány nebyly.

U proměnné EDB došlo ke zmírnění negativního vlivu. V jednorozměrném modelu byl tento vliv výrazně negativní a vysoce statisticky významný, zatímco ve vícerozměrném modelu se negativní vliv oslabil a p-hodnota vzrostla, i když významnost zůstala zachována. To naznačuje, že při zohlednění ostatních proměnných již není snadnost podnikání tak silným samostatným faktorem úspěšnosti startupu, jak se původně jevilo.

U prediktoru zachycující růst odvětví, ve kterém startup působí, byl v jednorozměrném modelu pozorován extrémně vysoký pozitivní vliv, který byl doprovázen velmi nízkou p-hodnotou. Ve vícerozměrném modelu se velikost tohoto vlivu snížila, ačkoli pozitivní směr a statistická významnost zůstaly zachovány. To ukazuje, že růst odvětví má na úspěch startupu pozitivní dopad i po započtení vlivů dalších faktorů, nicméně jeho efekt není tak extrémní, jak naznačovala jednoduchá analýza.

Změna vlastního kapitálu vykazovala v jednorozměrném modelu slabý pozitivní vliv, který byl na hranici statistické významnosti. Po zařazení do vícerozměrného modelu však p-hodnota výrazně vzrostla a prediktor se stal statisticky nevýznamným. To znamená, že změna vlastního kapitálu mezi prvním a čtvrtým rokem ztrácí při kontrole ostatních faktorů svůj predikční význam.

4.5.2. Stanovení významných prediktorů

Po sestavení vícerozměrného modelu obsahujícího všechny předem vybrané prediktory bylo přistoupeno k jeho optimalizaci s cílem zvýšit efektivitu predikce a omezit zbytečnou složitost modelu. Proto bylo přistoupeno k výběru nejvhodnější kombinace prediktorů, která zajistí rovnováhu mezi přesností a jednoduchostí modelu.

Prvním krokem bylo odstranění prediktoru „změna obratu“, jehož vyloučení vedlo ke snížení hodnoty AIC. Následně byl vyřazen také prediktor zachycující existenci dceřiné společnosti, které rovněž významně nepřispíval ke zlepšení predikční schopnosti modelu a jeho odstranění dále snížilo hodnotu AIC. Další odstranění prediktorů by již vedlo ke zhoršení AIC, a proto byla selekce ukončena.

Při dalším posuzování výsledného modelu byla zvážena relevance jednotlivých prediktorů nejen na základě optimalizace AIC, ale rovněž z hlediska jejich statistické významnosti. Přestože proměnná „vlastní kapitál“ zůstala v modelu po postupné selekci, její p-hodnota naznačovala absenci statisticky významného vlivu na úspěšnost startupů v přítomnosti ostatních prediktorů. Navíc její vyřazení vedlo pouze k minimálnímu zhoršení prediktivní schopnosti vycházející z matice záměn (pouze o 0.2 p. b.), což je změna, která je z

praktického hlediska zanedbatelná. Tento fakt je poměrně překvapující, jelikož hodnota AUC tohoto prediktoru byla nejvyšší ze všech vypočtených AUC v rámci jednorozměrného testování.

S ohledem na snahu o dosažení co nejjednoduššího a nejlépe interpretovatelného modelu bylo rozhodnuto tuto proměnnou z finálního modelu vyřadit.

Prediktory, které tedy budou použity v modelu jsou: HDP na obyvatele, míra nezaměstnanosti, index EDB, růst odvětví, dosažení stanovené likvidity a růst pracovního kapitálu.

Po tomto kroku je již možné stanovit finální model se všemi jeho prediktory a jejich vahami. Tento model vychází ze vzorce 1 a jeho dosazení vypadá následovně:

$$\text{logit}(p) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_6 x_6$$

$$\text{logit}(p) = 8.558 - 1.084 \cdot 10^{-4} \cdot x_1 + 0.140 \cdot x_2 - 0.106 \cdot x_3 + 2.667 \cdot x_4 + 1.404 \cdot x_5 + 1,259 \cdot 10^{-3} \cdot x_6 \quad (19)$$

Kde:

x_1 – HDP na obyvatele

x_2 – Míra nezaměstnanosti

x_3 – EDB index

x_4 – Růst odvětví

x_5 – Běžná likvidita

x_6 – Změna pracovního kapitálu

Je patrné, že se hodnoty β koeficientů mírně liší od těch vyčíslených v tabulce na začátku kapitoly 3.4. To je způsobeno vyloučením třech prediktorů z modelu. Kvůli tomu se čísla v rámci propočtů mírně upravila.

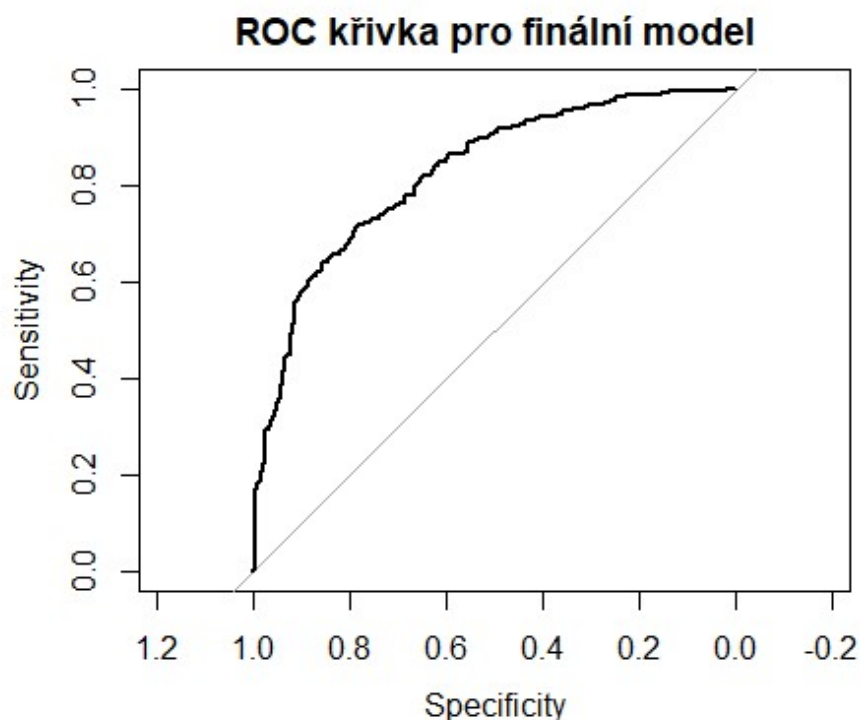
4.5.3. Zhodnocení predikční síly modelu

Pro zjištění predikční síly modelu byla sestavena matice záměn (tabulka č. 21) a ROC křivka (graf č. 10) spolu s vyčíslením hodnoty AUC. Hodnota AUC dosáhla 0.8253, což indikuje velmi dobrou schopnost modelu rozlišovat mezi úspěšnými a neúspěšnými podniky. Výsledek AUC byl následně testován pomocí DeLongova testu, který poskytl p-hodnotu menší než 0.05. Tento výsledek naznačuje, že model vykazuje statisticky významně lepší schopnost rozlišovat mezi pozitivními a negativními případy než náhodné rozhodování, které by odpovídalo AUC rovné 0.5.

Tabulka č. 21: Confusion matrix (predikce úspěšnosti dle vícerozměrného testování)

(Zdroj: Vlastní zpracování)

	Skutečnost 0	Skutečnost 1
Predikce 0	384	146
Predikce 1	103	366



Graf č. 10: ROC křivka – Vícerozměrné testování

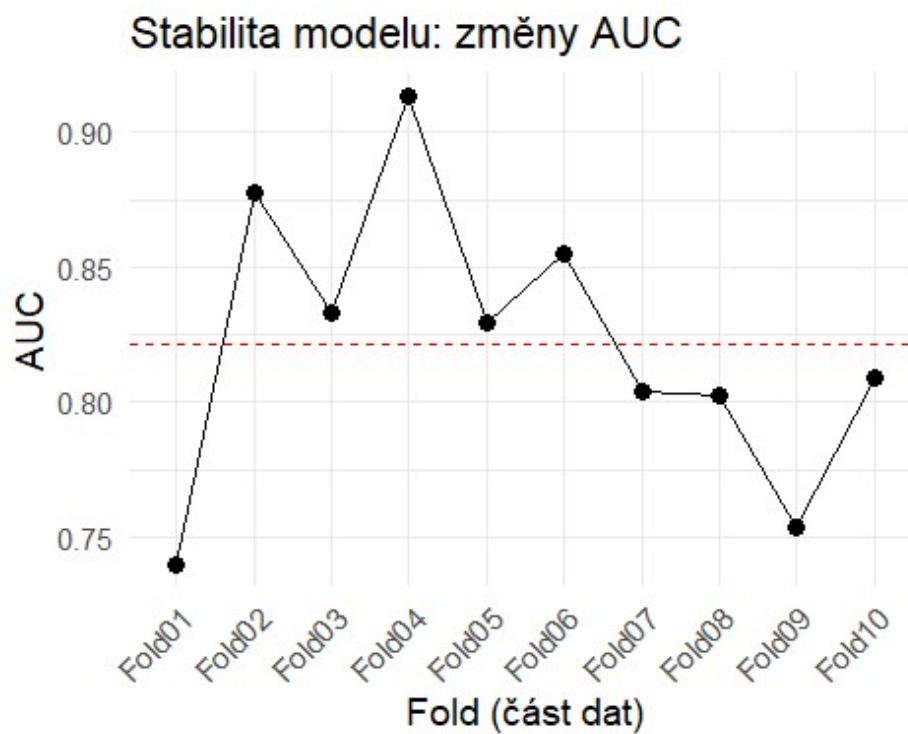
(Zdroj: vlastní zpracování)

Pro tento konkrétní model byla stanovena optimální výše cut-offu na základě maximálního Youdenova indexu, a to ve výši 0.5529. Pokud tedy model vrátí číslo vyšší než tohle, bude startup zařazen do kategorie „úspěšný“.

Při aplikaci tohoto optimálního cut-offu dosáhl model senzitivity 78.04 % a specifity 72.45 %, což svědčí o vyvážené schopnosti správně identifikovat jak úspěšné, tak neúspěšné startupy, i když ty neúspěšné dokáže model identifikovat o kus lépe. Celková přesnost klasifikace činila 75.08 %, což potvrzuje solidní prediktivní výkon modelu.

4.5.4. Vyhodnocení stability modelu

Pro ověření stability a robustnosti výsledného logistického regresního modelu byla provedena desetinásobná křížová validace (10-fold cross-validation).



Graf č. 11: Stabilita modelu: změny AUC

(Zdroj: vlastní zpracování)

Z křížové validace vychází průměrná hodnota AUC ve výši 0.822 a průměrné hodnoty senzitivity a specificity, které činí 0.70 resp. 0.76. I když průměr těchto dvou výsledků je lehce nižší než celková prediktivní schopnost modelu, ukazují tyto výsledky poměrně vysokou stabilitu modelu.

Grafické znázornění AUC hodnot v jednotlivých foldech podporuje závěr o konzistentním výkonu modelu. I přes jistou variabilitu zůstávají všechny hodnoty v rozmezí od 0.74 do 0.91, což svědčí o jeho prediktivní schopnosti a poměrně dobré stabilitě.

4.5.5. Praktický příklad

V této části bude vyčíslen praktický případ společnosti, která podniká v podmínkách určitého státu v daném čase. Nejprve budou této hypotetické společnosti přiřazeny hodnoty prediktorů, které budou relevantní na základě dat z datového souboru použitého k analýze. Poté bude vyčíslena pravděpodobnost jejího úspěchu. Bude vycházeno z modelu vytvořeného v této práci:

$$\begin{aligned} \text{logit}(p) = & 8.558 - 1.084 \cdot 10^{-4} \cdot x_1 + 0.140 \cdot x_2 - 0.106 \cdot x_3 + 2.667 \cdot x_4 + 1.404 \cdot x_5 \\ & + 1.259 \cdot 10^{-3} \cdot x_6 \end{aligned}$$

Výstupem logit modelu je číslo v intervalu od $-\infty$ do $+\infty$. Pro výpočet pravděpodobnosti, která bude v intervalu od 0 do 1, kde 1 je 100% šance na úspěch, je potřeba dosadit do vzorce logistické funkce (viz vzorec 4).

$$p = \frac{e^{\text{logit}(p)}}{1 + e^{\text{logit}(p)}}$$

Pro praktický příklad je nutné dosadit do vzorce relevantní hodnoty. Necht' jsou hodnoty prediktorů určeny následující tabulkou:

Tabulka č. 22: Hodnoty prediktorů pro praktický příklad

(Zdroj: vlastní zpracování)

Prediktor	Hodnota
HDP na obyvatele	20 000 USD
Míra nezaměstnanosti	5%
EDB index	75
Růst odvětví	20%
Běžná likvidita	1
Růst pracovního kapitálu	200%

Nyní budou hodnoty prediktorů dosazeny do modelu a bude vypočítána hodnota $\text{logit}(p)$ pro následný výpočet pravděpodobnosti.

$$\text{logit}(p) = 8.558 - 1.084 \cdot 10^{-4} \cdot 20\,000 + 0.140 \cdot 0.05 - 0.106 \cdot 75 + 2.667 \cdot 0.2 + 1.404 \cdot 1 + 1.259 \cdot 10^{-3} \cdot 2 \quad (20)$$

Výsledek je ve tvaru $\text{logit}(p) = 0.387$. Nyní je nutné dosadit do vzorce 4 a dopočítat výsledek. Po dosazení je získán výsledek 0.596. To znamená, že pravděpodobnost úspěchu při těchto zadaných hodnotách je 59.6 %.

$$p = \frac{e^{0.387}}{1+e^{0.387}} \approx 0.596 = 59.6 \% \quad (21)$$

ZÁVĚR

Startupy hrají klíčovou roli v rozvoji ekonomiky, přinášejí inovace, vytvářejí pracovní místa a podporují ekonomický růst. Navzdory svému vysokému potenciálu však čelí startupy mimořádně vysoké míře nejistoty a riziku selhání. Podle statistik přežije pouze malá část nově vzniklých firem své první roky a dosáhne dlouhodobého úspěchu. V tomto kontextu jsou modelování a predikce jejich úspěšnosti nesmírně důležité, neboť mohou výrazně přispět ke snižování investičního rizika a podpoře efektivního rozhodování zakladatelů, investorů a dalších zainteresovaných stran.

Cílem této diplomové práce bylo odvodit a ověřit vlastní model predikce úspěšnosti startupů na základě finančních a nefinančních ukazatelů. Dílčí cíle zahrnovaly definování pojmů startup či úspěch startupu, identifikaci faktorů ovlivňujících jejich úspěch, výběr relevantních finančních a nefinančních ukazatelů, analýzu vhodného vzorku dat a sestavení a ověření predikčního modelu, který by umožnil kvantifikovat pravděpodobnost úspěchu startupů. Tyto cíle byly v práci naplněny, přičemž postup zahrnoval jak teoretickou rešerši, tak praktickou aplikaci statistických metod.

Práce se ve své teoretické části zaměřila na vymezení pojmu startup a jeho významu pro ekonomiku, popsala specifika high-tech startupů a různé přístupy k měření jejich úspěšnosti. Dále byly identifikovány a popsány klíčové faktory, které ovlivňují úspěšnost startupů, včetně podnikových a vnějších faktorů. Praktická část zahrnovala popis analyzovaného vzorku a použitých metod, popis vlivů samostatných prediktorů a vytvoření vlastního predikčního modelu. Model byl následně otestován na reálných datech a vyhodnocen z hlediska jeho predikční síly a stability.

Výsledky testování modelu ukázaly, že vytvořený predikční model dosahuje velmi dobré úrovně přesnosti. Hlavní vícerozměrný model dosáhl hodnoty AUC 0.8253, což znamená, že model má silnou schopnost rozlišovat mezi úspěšnými a neúspěšnými startupy. Hodnota AUC přesahující 0.8 je obecně považována za velmi dobrou, protože indikuje, že model je schopný správně klasifikovat většinu případů. Statistická významnost tohoto výsledku byla taktéž potvrzena, což naznačuje, že výsledky nejsou dílem náhody. Celková přesnost

klasifikace modelu činila 75.08 %. Stabilita modelu byla dále potvrzena desetinásobnou křížovou validací, která přinesla průměrnou hodnotu AUC 0.822, což potvrzuje spolehlivost modelu i při práci s různými podmnožinami dat.

SEZNAM POUŽITÉ LITERATURY:

1. ACS, Zoltan J., ESTRIN, S., MICKIEWICZ, T., a SZERB, L. Entrepreneurship, institutional economics, and economic growth: an ecosystem perspective. *Small Business Economics*, 2018, 51: 501-514.
2. AUDRETSCH, David B.; THURIK, A. Roy. What's new about the new economy? Sources of growth in the managed and entrepreneurial economies. *Industrial and corporate change*, 2001, 10.1: 267-315.
3. BUCKLEY, Patricia a SAMADDAR, Monali. *Will growing wage pressures keep inflation high even when supply chain bottlenecks and energy pressures are resolved?* Online. 2022. Dostupné z: <https://www2.deloitte.com/us/en/insights/economy/spotlight/wage-increase-inflationary-pressure.html>. [cit. 2024-12-31].
4. BASKORO, Harjo, et al. Predicting startup success, a literature review. In: *Proceeding International Conference on Information Science and Technology Innovation*. 2022. p. 30-36.
5. CALLEN, Tim. *Gross Domestic Product: An Economy's All*. Online. International Monetary Fund. Dostupné z: <https://www.imf.org/en/Publications/fandd/issues/Series/Back-to-Basics/gross-domestic-product-GDP>. [cit. 2024-12-31].
6. COCKAYNE, Daniel. What is a startup firm? A methodological and epistemological investigation into research objects in economic geography. *Geoforum*, roč. 107 (2019), s. 77-87. ISSN 0016-7185
7. ČESKÝ STATISTICKÝ ÚŘAD. *Metodika - High-tech sektor*. Online. Dostupné z: <https://csu.gov.cz/metodika-high-tech-sektor>. [cit. 2025-03-16].
8. DÍAZ-SANTAMARÍA, Carlos; BULCHAND-GIDUMAL, Jacques. Econometric estimation of the factors that influence startup success. *Sustainability*, 2021, 13.4: 2242.

9. EUROPEAN INOVATION COUNCIL. Akcelerátor EIC. Online. Dostupné z: https://eic.ec.europa.eu/eic-funding-opportunities/eic-accelerator_en. [cit. 2025-03-08].
10. EUROSTAT. *High-tech classification of manufacturing industries*. Online. 2020. Dostupné z: https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Glossary:High-tech_classification_of_manufacturing_industries. [cit. 2024-12-31].
11. EUROSTAT. *High-tech*. Online. 2021. Dostupné z: <https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Glossary:High-tech>. [cit. 2024-12-31].
12. EUROSTAT. *Unemployment rate in the European Union and Europe as of September 2024, by country*. Online. 2024. Dostupné z: <https://www.statista.com/statistics/1115276/unemployment-in-europe-by-country/>. [cit. 2024-12-31].
13. FAILORY. *42 Failed Startups with No Market Need*. Online. 2022. Dostupné z: <https://www.failory.com/startups/no-market-need-failures>. [cit. 2025-03-08].
14. FAILORY. *90% of startups fail*. Online. Dostupné z: <https://www.failory.com/>. [cit. 2025-03-08].
15. FUNDERA. *Small Business Statistics: 19 Essential Numbers to Know*. Online. 2023. Dostupné z: <https://www.fundera.com/blog/small-business-statistics>. [cit. 2025-03-08].
16. GOMPERS, Paul; KOVNER, Anna; LERNER, Josh. Specialization and success: Evidence from venture capital. *Journal of Economics & Management Strategy*, 2009, 18.3: 817-844.
17. HASANI, Alireza; DARSARA, Mohammad Mehdi Ali Nejad; BAY, Shadi. Startups and their influence on economic Development. *World Journal of Environmental Biosciences*, 2020, 9.1-2020: 50-58.
18. HOLMES, Phil; HUNT, A.; STONE, Ian. An analysis of new firm survival using a hazard function. *Applied Economics*, 2010, 42.2: 185-195.

19. KANE, Tim J. The importance of startups in job creation and job destruction. *Available at SSRN 1646934*, 2010.
20. KIVILUOTO, N. *Rediscovering profitability in entrepreneurship: Evidence from Finnish high-technology start-ups*. 2011. Åbo Akademis förlag-Åbo Akademi University Press.
21. KIVILUOTO, Niklas. Growth as evidence of firm success: myth or reality?. *Entrepreneurship & Regional Development*, 2013, 25.7-8: 569-586.
22. MATOUŠKOVÁ, Zdeňka. Konkurenceschopnost regionů. Online. 2000. Dostupné z: <https://www.dvs.cz/clanek.asp?id=57270>. [cit. 2025-03-19].
23. MCGOWAN, Emma. *The 13 Top Reasons Why Startups Fail*. Online. STARTUPS. Dostupné z: <https://www.startups.com/articles/why-do-startups-fail>. [cit. 2025-03-08].
24. ODBOR KOMUNIKACE. *Česká republika je země start-upů a do roku 2030 chce patřit mezi inovační lídry*. Online. MPO. 2019. Dostupné z: <https://mpo.gov.cz/cz/rozcestnik/pro-media/tiskove-zpravy/ceska-republika-je-zeme-start-upu-a-do-roku-2030-chce-patrit-mezi-inovacni-lidry--251522>. [cit. 2025-03-16].
25. ODBOR VÝZKUMU, VÝVOJE A INOVACÍ. *Technologická inkubace start-upů*. Online. MPO. 2023. Dostupné z: <https://mpo.gov.cz/cz/podnikani/podpora-vyzkumu-a-vyvoje/technologicka-inkubace-startupu/technologicka-inkubace-startupu--275257/?utm>. [cit. 2025-03-08].
26. OECD. *Unemployment rate*. Online. Dostupné z: <https://www.oecd.org/en/data/indicators/unemployment-rate.html>. [cit. 2024-12-31].
27. OKRAH, James; NEPP, Alexander; AGBOZO, Ebenezer. Exploring the factors of startup success and growth. *The business & management review*, 2018, 9.3: 229-237.
28. RAY, D. Michael; VILLENEUVE, Paul Y.; ROBERGE, Roger A. Functional prerequisites, spatial diffusion, and allometric growth. *Economic Geography*, 1974, 50.4: 341-351.

29. ROBEHMED, Natalie. *What Is A Startup?* Online. Forbes. 2013. Dostupné z: <https://www.forbes.com/sites/natalierobehmed/%202013/12/16/what-is-a-startup/>. [cit. 2024-12-31].
30. RONG, Yuwei. The Significance and Contributions of Startups Driving Economic Growth. *Advances in Economics, Management and Political Sciences*, 2025, 149: 5-11.
31. ŘEHÁKOVÁ, Blanka. Introducing Logistic Regression, Metodická rubrika. *Sociologický časopis*. 2000, č. XXXVI, s. 475-492.
32. SAHU, Sagar; KSHATRIYA, Sunita. The Effects of GDP Growth, Inflation, and Interest Rates on Startup Survival Rates: A Cross-sectoral Perspective. *Integrated Journal for Research in Arts and Humanities*, 2024, 4: 135-139.
33. SELEY, John E. Targeting economic development: an examination of the needs of small businesses. *Economic Geography*, 1981, 57.1: 34-51.
34. TZABBAR, Daniel; MARGOLIS, Jaclyn. Beyond the startup stage: The founding team's human capital, new venture's stage of life, founder-CEO duality, and breakthrough innovation. *Organization science*, 2017, 28.5: 857-872.
35. WORLD BANK. *Ease of Doing Business Scores*. Online. 2020. Dostupné z: <https://archive.doingbusiness.org/en/data/doing-business-score?topic=>. [cit. 2024-12-31].
36. WORLD BANK. *Ease of doing business score and ease of doing business ranking*. Online. 2020. Dostupné z: <https://openknowledge.worldbank.org/server/api/core/bitstreams/2db10c90-db63-5746-a4e3-1bfe264dda7c/content>. [cit. 2024-12-31].
37. YEH, Chen. Why Are Startups Important for the Economy?. *Richmond Fed Economic Brief*, 2023, 23.06.

SEZNAM TABULEK:

Tabulka č. 1: Vývoj počtu podniků v high-tech odvětví (Zdroj: vlastní zpracování dle EUROSTAT)	18
Tabulka č. 2: Podíl high-tech podniků v ekonomice (Zdroj: vlastní zpracování dle EUROSTAT)	19
Tabulka č. 3: Seznam potenciálních prediktorů (Zdroj: vlastní zpracování).....	28
Tabulka č. 4: Obrat dle odvětví mezi lety (tis. USD) (Zdroj: vlastní zpracování)	34
Tabulka č. 5: Procentuální meziroční růst obratu dle odvětví (Zdroj: vlastní zpracování) ..	35
Tabulka č. 6: Popisná statistika neúspěšných startupů (Zdroj: vlastní zpracování)	47
Tabulka č. 7: Popisná statistika úspěšných startupů (Zdroj: vlastní zpracování)	47
Tabulka č. 8: Jednorozměrné testování (Zdroj: vlastní zpracování).....	49
Tabulka č. 9: jednorozměrné testování – intervaly spolehlivosti (Zdroj: vlastní zpracování)	49
Tabulka č. 10: AUC hodnoty jednorozměrných modelů a jejich statistická významnost (Zdroj: vlastní zpracování).....	59
Tabulka č. 11: Confusion matrix (predikce úspěšnosti podle výše HDP na obyvatele) (Zdroj: vlastní zpracování).....	60
Tabulka č. 12: Confusion matrix (predikce úspěšnosti podle míry nezaměstnanosti) (Zdroj: Vlastní zpracování)	62
Tabulka č. 13: Confusion matrix (predikce úspěšnosti podle hodnoty indexu snadnosti podnikání) (Zdroj: Vlastní zpracování)	64
Tabulka č. 14: Confusion matrix (predikce úspěšnosti podle míry růstu odvětví) (Zdroj: Vlastní zpracování)	66
Tabulka č. 15: Confusion matrix (predikce úspěšnosti podle změny vlastního kapitálu) (Zdroj: Vlastní zpracování).....	67

Tabulka č. 16: Confusion matrix (predikce úspěšnosti podle změny obratu) (Zdroj: Vlastní zpracování).....	69
Tabulka č. 17: Confusion matrix (predikce úspěšnosti podle běžné likvidity) (Zdroj: Vlastní zpracování).....	70
Tabulka č. 18: Confusion matrix (predikce úspěšnosti podle změny pracovního kapitálu) (Zdroj: Vlastní zpracování).....	72
Tabulka č. 19: Korelace mezi analyzovanými prediktory (Zdroj: vlastní zpracování)	74
Tabulka č. 20: Vícerozměrné testování (Zdroj: vlastní zpracování)	75
Tabulka č. 21: Confusion matrix (predikce úspěšnosti dle vícerozměrného testování) (Zdroj: Vlastní zpracování)	78
Tabulka č. 22: Hodnoty prediktorů pro praktický příklad (Zdroj: vlastní zpracování)	81

SEZNAM GRAFŮ:

Graf č. 1: Kaplan-Meierova křivka podniků dle počtu let v zisku (Zdroj: vlastní zpracování)	39
Graf č. 2: ROC křivka – HDP na obyvatele (Zdroj: vlastní zpracování)	61
Graf č. 3: ROC křivka – Míra nezaměstnanosti (Zdroj: vlastní zpracování)	63
Graf č. 4: ROC křivka – Index EDB (Zdroj: vlastní zpracování)	65
Graf č. 5: ROC křivka – Růst odvětví (Zdroj: vlastní zpracování)	67
Graf č. 6: ROC křivka – Změna vlastního kapitálu (Zdroj: vlastní zpracování)	68
Graf č. 7: ROC křivka – Změna výše obrátu (Zdroj: vlastní zpracování)	70
Graf č. 8: ROC křivka - Běžná likvidita (Zdroj: vlastní zpracování)	71
Graf č. 9: ROC křivka – Změna pracovního kapitálu (Zdroj: vlastní zpracování)	73
Graf č. 10: ROC křivka – Vícerozměrné testování (Zdroj: vlastní zpracování)	78
Graf č. 11: Stabilita modelu: změny AUC (Zdroj: vlastní zpracování)	79