

Prediktivní analýza v logistice

Jan Marák

Bakalářská práce
2025



Univerzita Tomáše Bati ve Zlíně
Fakulta logistiky a krizového řízení

Univerzita Tomáše Bati ve Zlíně

Fakulta logistiky a krizového řízení

Ústav logistiky

Akademický rok: 2024/2025

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení:	Jan Marák
Osobní číslo:	L24410
Studijní program:	B1041P040003 Aplikovaná logistika
Forma studia:	Prezenční
Téma práce:	Prediktivní analýza v logistice

Zásady pro vypracování

- Vypracujte literární rešerši zkoumané problematiky ze všech literárních zdrojů
- Představte vybranou firmu a popište, jak funguje jejich predikce v logistice a analyzovat ji
- Vyhodnoťte analyzovaný proces predikce a navrhněte přínosnější řešení do budoucna

Forma zpracování bakalářské práce: **tištěná/elektronická**

Seznam doporučené literatury:

1. ABBOTT, Dean. *Applied predictive analytics: principles and techniques for the professional data analyst*. Indianapolis: Wiley, [2014]. ISBN 978-1-118-72796-6.
 2. BAROT, Tomáš. *Prediktivní řízení procesů s rychlou dynamikou*. Doctoral thesis summary. Zlín: Univerzita Tomáše Bati ve Zlíně, 2016. ISBN 978-80-7454-627-3.
 3. GANGUR, Mikuláš. *Prediktivní trhy: principy, struktura a využití prediktivních trhů : pobídkové a motivační systémy prediktivních trhů : problematika implementace prediktivního trhu*. Praha: Wolters Kluwer, 2015. ISBN 978-80-7478-847-5.
 4. LEVENTHAL, Barry. *Predictive analytics for marketers: using data mining for business advantage*. London: Kogan Page, 2018. ISBN 978-0-7494-7993-0.
 5. MACUROVÁ, Pavla; KLABUSAYOVÁ, Naděžda a TVRDOŇ, Leo. *Logistika*. 2. upravené a doplněné vydání. Series of economics textbooks. Ostrava: VŠB-TU Ostrava, 2018. ISBN 978-80-248-4158-8.
 6. NABARESEH, Stephen. *Predictive analytics: a data mining technique in customer churn management for decision making*. Doctoral thesis summary. Zlín: Tomas Bata University in Zlín, 2017. ISBN 978-80-7454-649-5.
- Další odborná literatura dle doporučení vedoucího bakalářské práce.

Vedoucí bakalářské práce: **JUDr. Ivan Barančík, Ph.D.**
Ústav logistiky

Datum zadání bakalářské práce: **2. prosince 2024**
Termín odevzdání bakalářské práce: **2. května 2025**

L.S.

prof. Ing. Zuzana Tučková, Ph.D.
děkanka

prof. Ing. Zuzana Tučková, Ph.D.
ředitel ústavu

V Uherském Hradišti dne 2. prosince 2024

PROHLÁŠENÍ AUTORA BAKALÁŘSKÉ PRÁCE

Beru na vědomí, že

- odevzdáním bakalářské práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb., v platném znění bez ohledu na výsledek obhajoby;
- bakalářská práce bude uložena v elektronické podobě v univerzitním informačním systému a bude dostupná k nahlédnutí;
- jedno vyhotovení bakalářské práce v listinné podobě bude ponecháno Univerzitě Tomáše Bati ve Zlíně k uložení;
- na moji bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- podle § 60 odst. 1 autorského zákona má Univerzita Tomáše Bati ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- podle § 60 odst. 2 a 3 mohu užít své dílo – bakalářskou práci – nebo poskytnout licenci k jejímu využití jen s předchozím písemným souhlasem Univerzity Tomáše Bati ve Zlíně, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše);
- pokud bylo k vypracování bakalářské práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tj. k nekomerčnímu využití), nelze výsledky bakalářské práce využít ke komerčním účelům;
- pokud je výstupem bakalářské práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá; neodevzdání této součásti může být důvodem k neobhájení práce.

Prohlašuji, že

- jsem na bakalářské práci pracoval(a) samostatně a použitou literaturu jsem řádně citoval(a); v případě publikace výsledků budu uveden(a) jako spoluautor;
- odevzdaná verze bakalářské práce a verze elektronická nahraná do IS/STAG jsou obsahově totožné.

V Uherském Hradišti, dne 30.4.2025

.....
podpis autora

ABSTRAKT

MARÁK, JAN. *PREDIKTIVNÍ ANALÝZA V LOGISTICE*, 2025. UHERSKÉ HRADIŠTĚ: FAKULTA LOGISTIKY A KRIZOVÉHO ŘÍZENÍ UNIVERZITY TOMÁŠE BATI VE ZLÍNĚ, 88 S. BAKALÁŘSKÁ PRÁCE.

Tato bakalářská práce se zabývá využitím prediktivní analýzy v oblasti logistiky. Cílem je analyzovat moderní metody predikce, jako jsou regresní modely, neuronové sítě a časové řady, a jejich aplikaci v optimalizaci logistických procesů. Práce se zaměřuje na přínosy prediktivní analýzy při řízení skladových zásob, plánování přepravních cest a snižování logistických rizik. Na základě analýzy dat získaných z praktických případových studií se hodnotí efektivita prediktivních metod v různých oblastech logistického řízení. Výsledky ukazují, že prediktivní analýza má zásadní význam pro zlepšení rozhodovacích procesů a efektivní řízení zásobování.

Klíčová slova: prediktivní analýza, logistika, regresní modely, neuronové sítě, časová řada, řízení zásob, plánování dopravy

ABSTRACT

MARÁK, JAN. *PREDICTIVE ANALYTICS IN LOGISTICS*, 2025. UHERSKÉ HRADIŠTĚ: FACULTY OF LOGISTICS AND CRISIS MANAGEMENT, UNIVERSITY OF TOMÁŠ BATA IN ZLÍN, 88 P. BACHELOR THESIS.

This bachelor thesis deals with the use of predictive analytics in the field of logistics. The aim is to analyze modern prediction methods such as regression models, neural networks and time series and their application in the optimization of logistics processes. The paper focuses on the benefits of predictive analysis in inventory management, transportation planning and logistics risk reduction. Based on the analysis of data obtained from practical case studies, the effectiveness of predictive methods in different areas of logistics management is evaluated. The results show that predictive analysis is essential for improving decision-making processes and effective supply management.

Keywords: predictive analysis, logistics, regression models, neural networks, time series, inventory management, transport planning

Rád bych poděkoval JuDr. Ivanu Barančíkovi, Ph.D. za odborné vedení této práce, užitečné poznámky a ochotu sdílet své zkušenosti. Jeho podpora a trpělivost pro mě byly velmi cenné během celého procesu jejího zpracování.

Zároveň děkuji všem respondentům, kteří se zapojili do dotazníkového šetření a rozhovorů. Jejich otevřenost a ochota podělit se o své znalosti výrazně přispěly k celkové kvalitě práce.

OBSAH

ÚVOD.....	13
I TEORETICKÁ ČÁST.....	15
1 ÚVOD DO ANALYTIKY.....	16
1.1 DEFINICE ANALYTIKY	16
1.2 SEGMENTACE ANALYTIKY.....	16
1.2.1 Deskriptivní analytika	17
1.2.2 Diagnostická analytika	18
1.2.3 Prediktivní analytika	19
1.2.4 Preskriptivní analytika	19
2 PREDIKTIVNÍ ANALÝZA.....	21
2.1 REGRESNÍ ANALÝZA.....	21
2.1.1 Provádění regresní analýzy	22
2.2 STROJOVÉ UČENÍ A VYUŽITÍ VELKÝCH DAT	24
2.3 NEURONOVÉ SÍTĚ	25
2.3.1 Praktické problémy při trénování neuronových sítí.....	25
2.4 ČASOVÁ ŘADA	26
2.4.1 Diskrétní deterministické a statistické časové řady	26
2.5 VÝZNAM A APLIKACE PREDIKTIVNÍ ANALÝZY V RŮZNÝCH ODVĚTVÍCH	27
2.5.1 Prediktivní analýza v obchodu a marketingu	27
2.5.2 Prediktivní analýza v medicíně	28
2.5.3 Prediktivní analýza v průmyslu.....	29
2.6 DATA MINING.....	30
2.7 ŘÍZENÍ DAT PRO ÚČELY PREDIKTIVNÍ ANALÝZY	30
2.8 JAKOU ROLI MAJÍ DATA?	31
2.8.1 Vývojová role.....	31
2.8.2 Role nasazení	31
2.8.3 Popisující role.....	32
2.9 JAK JSOU DATA UŽITEČNÁ PRO PREDIKTIVNÍ ANALÝZU V LOGISTICE?	32
2.10 JAK DŮLEŽITÉ JE, MÍT K DISPOZICI SPRÁVNÁ DATA?	33
2.10.1 Strukturovaná data	34
2.10.2 Nestrukturovaná data	34
2.11 PŘÍPRAVA DAT	34
2.12 PREDIKCE CHOVÁNÍ ZÁKAZNÍKŮ	35
2.12.1 Chování spotřebitelů a Big dat.....	36
2.12.2 Faktory ovlivňující chování spotřebitelů	37
2.13 PREDIKTIVNÍ POPTÁVKY.....	38

2.13.1	Technologie a metody	38
2.13.2	Oblasti využití	39
2.13.3	Výhody a výzvy.....	39
2.14	PLÁNOVÁNÍ PŘEPRAVNÍCH CEST	40
2.14.1	Plánování dodavatelského řetězce.....	40
2.14.2	Problémy a otázky	41
2.14.3	Plánování a rozvrhování výroby.....	42
2.14.4	Návrh logistických sítí.....	42
2.15	PREDIKCE A MINIMALIZACE LOGISTICKÝCH RIZIK	43
2.15.1	Risk management	43
2.15.2	Pět kroků řízení rizik	45
II	PRAKTICKÁ ČÁST	46
3	PRAKTICKÉ VYUŽITÍ PREDIKTIVNÍ ANALÝZY VE SPOLEČNOSTI IM BENEFIT	47
3.1	VÝBĚR A POPIS SPOLEČNOSTI	47
3.2	ANALÝZA DAT A IMPLEMENTACE PREDIKTIVNÍCH MODELŮ.....	47
4	ANALYTICKO-EMPIRICKÁ ČÁST	50
4.1	ANALÝZA NASBÍRANÝCH DAT	50
4.1.1	Metodologie sběru dat	50
4.1.2	Zpracování dat.....	50
4.1.3	Praktická aplikace regresní analýzy v oblasti stavebních projektů	51
4.1.4	Lineární regrese.....	54
4.1.5	Analýza časové řady pomocí ARIMA modelu	59
4.2	VÝSLEDKY A JEJICH INTERPRETACE	64
4.2.1	Vyhodnocení výsledků Lineární regresní analýzy	64
4.2.2	Vyhodnocení výsledků predikce pomocí ARIMA modelu.....	66
4.3	DISKUSE NAD VÝSLEDKY.....	67
4.4	POLOSTRUKTUROVANÉ ROZHOVORY	68
5	NÁVRHOVÁ ČÁST	70
5.1	DOPORUČENÍ A NÁVRHY NA ZLEPŠENÍ.....	70
5.1.1	Optimalizace skladových zásob	70
5.1.2	Strategické plánování investic.....	70
5.1.3	Cenová optimalizace	71
5.1.4	Logistická synchronizace	72
5.2	KONKRÉTNÍ KROKY PRO IMPLEMENTACI DOPORUČENÝCH ZMĚN.....	72
5.2.1	Zavedení systému prediktivního řízení skladových zásob	73
5.2.2	Optimalizace rozpočtového plánování	73
5.2.3	Zavedení sezónního cenového modelu.....	74
5.2.4	Automatizovaná logistická synchronizace	74
5.3	ODHAD NÁKLADŮ A PŘÍNOSŮ NAVRHOVANÝCH ZMĚN.....	75

5.4	MOŽNOSTI DALŠÍHO VÝZKUMU V OBLASTI PREDIKTIVNÍ ANALÝZY V LOGISTICE	76
5.5	NAVRHOVANÉ SMĚRY PRO ROZŠÍŘENÍ A PROHLoubENÍ STÁVAJÍCÍCH POZNATKŮ.....	77
ZÁVĚR		79
SEZNAM POUŽITÉ LITERATURY.....		81
SEZNAM OBRÁZKŮ		83
SEZNAM TABULEK.....		84
SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK.....		85

ÚVOD

Tato bakalářská práce se zaměřila na využití prediktivní analytiky v logistice a její aplikaci ve společnosti IM BENEFIT. Hlavním cílem bylo analyzovat možnosti prediktivních metod v oblasti řízení skladových zásob, plánování přepravy a optimalizace podnikových procesů. Praktická část práce kombinovala kvantitativní analýzu s kvalitativním přístupem ve formě strukturovaných rozhovorů, které poskytly hlubší vhled do využití prediktivních modelů v praxi.

První výzkumná otázka se zaměřila na možnosti efektivního využití regresní analýzy k predikci rozsahu stavebních prací na základě investovaného rozpočtu. Výsledky regresní analýzy potvrdily existenci pozitivní korelace mezi výší investic a počtem realizovaných stavebních prací. První hypotéza, která předpokládala, že vyšší investice vedou k většímu objemu realizovaných prací, byla potvrzena. Analýza ukázala, že regresní modely mohou být užitečným nástrojem pro predikci rozsahu stavebních projektů, což usnadňuje strategické plánování investic.

Druhá výzkumná otázka se zaměřovala na přesnost modelu ARIMA při předpovědi sezónních výkyvů poptávky po stavebních materiálech. ARIMA model byl aplikován na historická data prodeje a poskytl přesné predikce očekávaného vývoje poptávky. Výsledky potvrdily sezónní charakter poptávky po stavebních materiálech, přičemž nejvyšší prodeje byly zaznamenány v teplejších měsících. Druhá hypotéza, která předpokládala schopnost ARIMA modelu přesně předpovědět sezónní výkyvy poptávky, byla potvrzena. Model umožňuje podnikům efektivně plánovat skladové zásoby, minimalizovat náklady a optimalizovat zásobovací strategie.

Strukturované rozhovory s vedoucím skladu společnosti IM BENEFIT potvrdily praktický přínos prediktivní analýzy v logistických operacích. Respondent zdůraznil, že správné predikce poptávky umožňují efektivnější řízení skladových zásob, optimalizaci přepravních procesů a celkovou zlepšenou alokaci zdrojů. Díky využití prediktivních metod společnost lépe předvídá sezónní výkyvy, což se pozitivně odráží na provozní efektivitě a kvalitě služeb.

Práce zároveň poukazuje na výzvy spojené s implementací prediktivní analytiky. Regresní analýza nezahrnuje všechny faktory ovlivňující rozsah stavebních projektů, například kvalitu pracovní síly nebo ekonomické podmínky. ARIMA model zase reflektuje pouze historické trendy a nemusí vždy správně zachytit neočekávané tržní změny. Z tohoto

důvodu je doporučeno rozšíření výzkumu o další faktory, jako jsou makroekonomické indikátory, meteorologická data nebo konkurenční analýzy.

Prediktivní analytika v logistice představuje klíčový nástroj moderního podnikání, který umožňuje efektivnější rozhodování založené na datech. Výsledky této práce potvrzují, že správně nastavené analytické modely mohou přispět ke zlepšení výkonnosti podniků v oblasti logistiky, snížení provozních nákladů a optimalizaci plánovacích procesů. Další výzkum v této oblasti by se měl zaměřit na rozšíření prediktivních metod, integraci pokročilých analytických technik a testování jejich aplikace v různých odvětvích.

I TEORETICKÁ ČÁST

1 ÚVOD DO ANALYTIKY

1.1 Definice analytiky

Jako první bych rád uvedl, co to vlastně analytika je a jak se liší od analýzy. Slovník Cambridge (2015) představuje pojem analýza jako „proces studia nebo zkoumání něčeho organizovaným způsobem, aby se o tom dozvěděl více, nebo konkrétní studium něčeho.“

Jako další definici pro analytiku jsem vybral jednu, která sice zní neobvykle, ale na první pohled zaujme. „Zkoumání látky, zejména rozdělením na části, aby se zjistilo, co je nebo co obsahuje“ (Cambridge University Press, 2025).

Oracle (2021) definuje analytiku jako „proces objevování, interpretace a sdělování významných vzorců v datech.“

Analytiku lze také chápat jako „akt podrobného studia nebo zkoumání něčeho, abyste o tom zjistili nebo pochopili více, nebo váš názor a úsudek po tomto studiu“ (Cambridge University Press, 2025).


V knize Predictive Analytics for Marketers, je analytika definována srozumitelnějším způsobem. „Prediktivní analytika je souhrnný pojem pro použití matematických technik k předvídání chování zákazníků. Výsledkem je obvykle skóre nebo kód pro každého zákazníka, který určitým způsobem naznačuje jeho pravděpodobné budoucí chování“ (Leventhal, 2018).

1.2 Segmentace analytiky

Analýza dat je tedy obecně proces, kterým získáváme informace z dat. Jak tedy dokážeme členit analytiku? Analytika se dá členit na základní formy, které zahrnují (Toombs, 2.2.2024):

- 1) Deskriptivní analytika
- 2) Diagnostická analytika
- 3) Prediktivní analytika
- 4) Preskriptivní analytiku

Deskriptivní analytika se například ptá na otázku, co se stalo. Diagnostická analytika se zabývá otázkou, proč se to stalo, prediktivní poté, co se může stát a nakonec preskriptivní, jak to můžeme uskutečnit. Tyto otázky ke každé jedné z analytik pomáhají chápat, rozdíl mezi nimi a proč například nepoužíváme deskriptivní analytiku, když je potřeba použít prediktivní.



Obrázek 1: Gartnerův model analytického vzestupu (TALEND TEAM, 2022)

Hodnota analytiky je reprezentována na ose Y, zatímco její obtížnost je znázorněna na ose X. Šipka ve středu ukazuje plynulý postup růstu, doprovázený pojmy jako informace, zpětný pohled, vhled, předvídání a optimalizace. Deskriptivní analytika je nejméně náročná, což se odráží v její nižší hodnotě, zatímco preskriptivní analytika je nejvíce komplexní a poskytuje nejvyšší hodnotu. Jednotlivé typy analytiky na sebe navazují, přičemž každá z nich pracuje s poznatky získanými z předchozí. Z historických dat získáváme klíčové informace a zpětný pohled, který se následně transformuje na hlubší vhled. Ten slouží jako základ pro predikci, která na závěr umožňuje optimalizovat rozhodovací proces. (Nik, 2020)

1.2.1 Deskriptivní analytika

Deskriptivní analytika je užitečná pro identifikaci vzorců, potenciálních problémů a jejich následné řešení. Například analýzou tržeb a příjmů lze snadno určit období s nejvyššími

a nejnižšími prodeji. Tyto poznatky mohou být následně využity k optimalizaci marketingových a prodejních strategií. (Toombs, 2024)

Proč je deskriptivní analýza důležitá? Deskriptivní analýza poskytuje důležité informace o minulých výkonech a chování, které nemusí být na první pohled zřejmé. Díky těmto poznatkům je možné efektivně přizpůsobit strategie a řešit identifikované problémy. V kombinaci s dalšími typy analytiky slouží historická data jako pevný základ pro plánování a vytváření rozpočtů.

1.2.2 Diagnostická analytika

Diagnostická analytika se zaměřuje na identifikaci příčin a faktorů, které vedly k minulým událostem nebo trendům. Zatímco popisná analytika poskytuje přehled o tom, co se stalo, diagnostická analytika odpovídá na otázku, proč k tomu došlo. Jedná se o proces analýzy kořenových příčin, který se často využívá pro pochopení vlivu konkrétních proměnných na danou situaci, podobně jako u regresní analýzy.

Obě analytiky spolu úzce souvisejí – zatímco popisná analytika odhaluje minulé trendy, diagnostická analytika hledá důvody jejich vzniku. Tento přístup je nepostradatelný při přijímání nápravných opatření a úpravách strategií. Například pokud dochází ke zpožděním při doručování objednávek, podrobná analýza balicích a expedičních procesů může pomoci identifikovat hlavní příčinu problému. Stejným způsobem lze zjistit příčiny problémů v dodavatelském řetězci, zásobování nebo kontrole kvality. (Toombs, 2024)

Díky diagnostické analytice je možné efektivněji řešit úzká místa ve výrobě či logistice, což umožňuje zvýšení výkonnosti a snížení rizika opakování problémů.

A znovu otázka, proč je tahle analytika důležitá? Proč bychom o ni měli vědět? Diagnostická analýza se specializuje na objasnění příčin a důsledků specifických obchodních situací. Zatímco jiné analytické metody excelují v identifikaci pozitivních či negativních trendů, diagnostická analytika umožňuje zjistit, co tyto trendy způsobilo. Tento přístup poskytuje neocenitelné poznatky, které lze využít k nápravě nedostatků nebo k opětovnému dosažení úspěchů z minulosti. (Toombs, 2024)

1.2.3 Prediktivní analytika

Prediktivní analytika se zaměřuje na odhad budoucích událostí a trendů, přičemž k tomu využívá historická data a statistické algoritmy. Tento přístup, který historicky stavěl na statistických modelech, je dnes díky pokročilým technologiím, jako je umělá inteligence a strojové učení, mnohem přesnější (Toombs, 2024).

Tento typ analytiky vychází z poznatků získaných deskriptivní a diagnostickou analýzou, na jejichž základě předpovídá, jak mohou zjištěné vzorce ovlivnit budoucí vývoj. Prediktivní analytika tím umožňuje aktivní přístup k rozhodování, například při tvorbě rozpočtů, finančních prognóz, plánování investic nebo řízení poptávky.

Její využití však přesahuje finance a trh. Ve výrobním průmyslu slouží prediktivní analytika k identifikaci a prevenci možných poruch strojů. V oblasti zdravotnictví umožňuje lépe identifikovat rizikové pacienty a navrhnout personalizované léčebné postupy. Ve finančních institucích nachází uplatnění při predikci podvodných aktivit nebo při hodnocení úvěrových rizik. (Toombs, 2024)

Proč bychom měli mít vědomosti i o prediktivní analytice? Prediktivní modely lze přirovnat k nástroji, který umožňuje přesnější předpovědi a efektivnější plánování. Prediktivní analýza však nezůstává pouze u identifikace vzorců a trendů, rozšiřuje tento přístup tak, aby poskytla hlubší porozumění budoucímu vývoji trhů a obchodních podmínek. (Toombs, 2024)

1.2.4 Preskriptivní analytika

Preskriptivní analýza slouží k podpoře rozhodovacího procesu prostřednictvím návrhů a doporučení, která vycházejí z výsledků prediktivní analýzy a analýzy historických dat. Tento přístup využívá pokročilé algoritmy, datovou vědu a systémy založené na pravidlech k vytvoření optimalizovaných rozhodnutí. Zatímco prediktivní analytika odpovídá na otázku „Co se pravděpodobně stane?“, preskriptivní analytika řeší otázku „Jaké kroky je vhodné podniknout?“.

Díky zohlednění specifických obchodních podmínek a tržních omezení umožňuje preskriptivní analytika flexibilně reagovat na dynamické změny moderního digitálního světa. Vedoucí pracovníci mohou s její pomocí přizpůsobovat svá rozhodnutí v reálném čase. Typická preskriptivní řešení zahrnují interaktivní vizualizace dat, které poskytují

přehled o různých rozhodovacích možnostech a jejich potenciálních dopadech, což usnadňuje výběr optimální strategie pro konkrétní podnikatelské situace (Toombs, 2024).

Proč je důležitá preskriptivní analytika? Preskriptivní analytika navrhuje různé možnosti řešení konkrétního obchodního scénáře, čímž umožňuje zvolit optimální postup. Tento přístup zároveň minimalizuje riziko nevhodných rozhodnutí a zajišťuje, že vybraná varianta bude co nejlépe přizpůsobena k dosažení maximálního přínosu.

2 PREDIKTIVNÍ ANALÝZA

Tak ještě jednou, ale o trochu jinak, co je to prediktivní analýza? Prediktivní analýza je metodický postup zahrnující využití matematických technik k odhadu budoucího chování zákazníků. Výsledkem této analýzy bývá skóre nebo kód, který je přiřazen jednotlivým zákazníkům a poskytuje informaci o jejich pravděpodobném budoucím jednání. Skóre například může vyjadřovat, jak vysoká je pravděpodobnost, že zákazník zakoupí další produkt dané společnosti. Kód pak může rozdělit zákazníky do skupin s odlišnými potřebami, například v oblasti komunikace, řízení nebo nabídky produktů a služeb. (Leventhal, 2018, s. 5)

Klíčovým přínosem těchto dat je možnost individuálního přístupu k zákazníkům na základě jejich specifických potřeb. Skóre může být využito k určení zákazníků, kteří mají největší pravděpodobnost, že zareagují na marketingovou kampaň. Naopak lze vytipovat zákazníky s nejmenší pravděpodobností nákupu a tyto osoby vyřadit z kampaně.

Takové cílené využití pravděpodobností umožňuje zvýšit efektivitu marketingových aktivit, které dosahují lepších výsledků než náhodné oslovení potenciálních zákazníků (Leventhal, 2018, s. 5).

Podle Abbotta (2014, s. 3) je prediktivní analýza proces zaměřený na identifikaci zajímavých a relevantních vzorců v datech. Tento přístup využívá poznatky z různých oblastí, které se zabývají odhalováním vzorců v datech již více než století, jako jsou rozpoznávání vzorů, statistika, strojové učení, umělá inteligence a dolování dat.

Od ostatních typů analýzy se prediktivní analýza liší tím, že je založena na datech. Klíčovým rysem je, že algoritmy odvozují charakteristiky modelů přímo ze samotných dat, namísto využití předem stanovených předpokladů analytika. Jinými slovy, algoritmy pracující na základě dat vytvářejí modely indukci. Tento indukční proces zahrnuje určení proměnných zahrnutých v modelu, parametrů definujících model, vah nebo koeficientů modelu, případně jeho celkovou složitost. (Abbott, 2014, s. 3)

2.1 Regresní analýza

Regresní analýza se zabývá zkoumáním vztahů mezi proměnnými. Slouží k objasnění otázky, jakým způsobem jeden nebo více prediktorů ovlivňuje sledovanou odezvu. Regresní analýza, stejně jako většina statistických metod, si klade za cíl co nejjednodušeji,

nejpraktičtěji a nejprehledněji shrnout dostupná data. V některých situacích je možné využít již existující teorii, která popisuje, jak se odezva mění v závislosti na hodnotách prediktorů. Pokud teorie není k dispozici, je třeba rozhodnutí o dalším postupu odvodit přímo z dat. Bez ohledu na dostupnost teorie je základním krokem při regresní analýze vizualizace dat prostřednictvím vhodných grafických zobrazení. (Weisberg, 2014, s.1)

Regresní analýza se opírá o základní grafické nástroje, které slouží k prozkoumání závislostí mezi proměnnými. Při analýze vztahu jednoho prediktoru a jedné odezvy je bodový graf zobrazující odezvu proti prediktoru klíčovým výchozím bodem. Pokud jde o problémy s více prediktory, je nutné na začátku analýzy použít několik jednoduchých grafů. Maticové bodové grafy jsou praktickým nástrojem, který umožňuje zobrazit velké množství bodových grafů najednou. Pomocí těchto grafů a jejich uspořádání lze získávat cenné informace, které podporují pochopení vztahů mezi proměnnými. (Weisberg, 2014, s. 1–2)

2.1.1 Provádění regresní analýzy


Pro zajištění správného použití regresní analýzy je důležité splnit několik klíčových požadavků na data. Tyto zahrnují:

- * Velikost vzorku: Je nutné pracovat s dostatečně velkým množstvím dat, aby bylo možné zajistit spolehlivost výsledků analýzy.

- * Variabilita proměnných: Proměnné musí obsahovat různé hodnoty, které umožňují sledování jejich vzájemných vztahů.

- * Typ škály závislé proměnné: Závislá proměnná by měla být měřena na vhodné škále, například intervalové nebo poměrové, aby analýza byla relevantní.

- * Kolinearita: Nezávislé proměnné by neměly být mezi sebou silně korelované, protože by to mohlo ovlivnit přesnost a interpretaci modelu. (Sarstedt et al., 2014, s. 196-198)



Obrázek 2: Bodový graf zobrazující pouze dvojici s výškou matek zaokrouhlenou na 58, 64, nebo 68 palců (Weisberg, 2014, s. 3)

Scatterplots, tedy bodové grafy, jsou klíčovým nástrojem pro analýzu vztahů mezi proměnnými. Bodový graf na obrázku 2, zobrazující výšku matek proti výšce dcer ukazuje, že rozsah hodnot je podobný u obou skupin, což umožňuje použít osy grafu se stejnými délkami a měřítky. Pokud by výšky matek a dcer byly identické, všechny body by ležely na přímce pod úhlem 45° . Při vytváření bodového grafu je důležité zohlednit potenciální přehlcení dat (tzv. overplotting), kdy více bodů leží na stejném místě. Řešením je použití jitteringu, který přidává k hodnotám malý náhodný posun, což zlepšuje čitelnost grafu. (Weisberg, 2014, s. 3)

Scatterplots také slouží k posouzení závislosti mezi proměnnými. Pokud se vertikální variabilita hodnot odezvy liší pro jednotlivé hodnoty prediktorů, závislost zde může být

významná. V případech s více prediktory je užitečné používat maticové bodové grafy pro vizualizaci většího množství vztahů současně. (Weisberg, 2014, s. 3)

Nakonec bodové grafy umožňují identifikaci odlehlých hodnot (outliers) a extrémních bodů (leverage points). Tyto hodnoty mohou mít významnou roli při odhadu regresních modelů a vyžadují specifickou interpretaci. (Weisberg, 2014, s. 3)

Bodové grafy představují zásadní nástroj pro zkoumání vztahů mezi proměnnými a umožňují identifikaci klíčových charakteristik dat, jako jsou závislosti, odlehlé hodnoty a extrémní body. Jejich správná konstrukce a interpretace, například pomocí technik jako jittering, zlepšují čitelnost a přesnost analýzy. U složitějších vztahů s více prediktory je užitečné využít maticové bodové grafy, které umožňují efektivní vizualizaci a porozumění datům. (Weisberg, 2014, s. 4)

2.2 Strojové učení a využití velkých dat

Strojové učení využívá pokročilé algoritmy k práci s big daty, což umožňuje podnikům lépe pochopit důležité aspekty jejich fungování. Tento proces je klíčovým prvkem nejen při zkoumání marketingových trendů, ale také při rozhodování na základě konkrétních datových podkladů, které hodnotí potenciální přínosy jednotlivých faktorů. Algoritmy a statistické modely strojového učení efektivně analyzují datové sady, čímž podporují rozhodování o produktivitě. Systémy navíc dokážou předpovědět události v tržních strukturách, což je zásadní pro plánování a optimalizaci. (Liu, 2023, s.1057)

Jak nám ale big data pomůžou? Využívání algoritmů big dat umožňuje organizacím předvídat chování zákazníků na základě různých faktorů, jako jsou prodejní trendy, tržní optimalizace, plánování úrovně produkce, řízení inventáře nebo detekce možných podvodů. Strojové učení a analýza velkých dat zahrnují také segmentaci zákazníků, analýzu přínosů jednotlivých skupin, porovnávání získaných dat a jejich využití v marketingových kampaních. Tyto kroky umožňují přizpůsobit obchodní strategie aktuálním potřebám zákazníků. (Liu, 2023, s.1057–1058)

Firmy díky těmto přístupům získávají schopnost přesně odhadnout pravděpodobnost nákupního chování na základě psychologických, sociálních, kulturních, osobních nebo ekonomických proměnných. Zatímco strojové učení se zaměřuje na výuku algoritmů k dosažení požadovaných výsledků, analýza velkých dat využívá statistické nástroje

k vytváření závěrů, které podporují rozvoj a růst podnikání. Oba tyto přístupy se doplňují, přispívají k efektivnímu rozhodování a umožňují podnikům lépe reagovat na dynamiku trhu. (Liu, 2023, s.1058)

Integrace strojového učení a velkých dat tak poskytuje firmám možnost zlepšit jejich operace, porozumět spotřebitelským trendům a optimalizovat rozhodovací procesy, které mají zásadní vliv na marketingové strategie a celkový obchodní výkon.

2.3 Neuronové sítě

Neuronové sítě jsou inspirovány způsobem, jakým funguje mozek, kde jsou neurony propojeny synapsemi. V umělých neuronových sítích se tento proces napodobuje prostřednictvím propojených výpočetních jednotek, jejichž váhy se upravují na základě chybových hodnot. Tento proces zlepšuje přesnost předpovědí a umožňuje sítím efektivně zpracovávat data. Pomocí tréninkových dat, která obsahují vstupy a odpovídající výstupy, se síť učí přizpůsobovat svůj model pro nové situace. Síla těchto sítí spočívá v kombinaci jednoduchých komponent, což jim umožňuje zachycovat složitější vztahy a struktury než klasické modely. (Aggarwal, 2018, s. 1)

Hluboké neuronové sítě dokážou efektivně simulovat rozpoznávání objektů díky inspiraci strukturou biologických sítí. Jejich výkonnost spočívá v propojení jednoduchých jednotek a schopnosti zpracovávat složité funkce dat. Pokroky v návrhu architektur, jako je konvoluční neuronová síť, umožnily jejich úspěšné využití v oblasti rozpoznávání obrazů. Tento přístup byl inspirován výzkumem vizuálního kortexu, který poskytl základní znalosti pro konstrukci těchto modelů. (Aggarwal, 2018, s. 1-2)

2.3.1 Praktické problémy při trénování neuronových sítí

Trénování neuronových sítí čelí výzvě, jako je přeučení, které nastává, když model dobře funguje na tréninkových datech, ale ne na nových případech. Tento problém je obzvláště výrazný u složitých modelů nebo malých datových sad. Řešením je zvýšení množství tréninkových dat nebo optimalizace komplexnosti modelu, aby se zlepšila schopnost generalizace. Důležitým faktorem je vyvážení mezi biasem (systematickými chybami) a variancí (citlivostí na šum), což ovlivňuje přesnost predikce. V posledních letech se neuronové sítě staly efektivní díky větším datovým sadám, ale stále vyžadují pečlivý

návrh, aby minimalizovaly přeučení. Trénování neuronových sítí čelí výzvám, jako je přeučení, které nastává, když model dobře funguje na tréninkových datech, ale ne na nových případech. Tento problém je obzvláště výrazný u složitých modelů nebo malých datových sad. Řešením je zvýšení množství tréninkových dat nebo optimalizace komplexnosti modelu, aby se zlepšila schopnost generalizace. Důležitým faktorem je vyvážení mezi biasem (systematickými chybami) a variancí (citlivostí na šum), což ovlivňuje přesnost predikce. V posledních letech se neuronové sítě staly efektivní díky větším datovým sadám, ale stále vyžadují pečlivý návrh, aby minimalizovaly přeučení. (Aggarwal, 2018, s. 24-25)

2.4 Časová řada

Časová řada představuje soubor hodnot, které jsou zaznamenávány v průběhu času v určitém sledu. Tyto hodnoty mohou být kontinuální, kdy data jsou sbírána nepřetržitě, nebo diskrétní, kdy jsou zaznamenávány v pevně stanovených časových intervalech. U diskrétních časových řad se jednotlivé hodnoty obvykle zapisují jako sled pozorování v konkrétních časových bodech. Tyto časové body lze definovat pomocí počátečního bodu a časového intervalu, což vytváří rovnoměrně rozložené okamžiky v čase, například počáteční bod plus zvolený interval. (Box et al., 2016, s. 21)

Jak se ale liší od ostatních? Přesné určení počátečního času a intervalu není pro mnoho analýz nezbytné, pokud není nutné přesně specifikovat časové body. Pokud však stanovíme počáteční bod jako výchozí čas a interval jako jednotku času, můžeme každé pozorování chápat jako hodnotu odpovídající určitému okamžiku. Diskrétní časové řady hrají důležitou roli při analýze dat, například pro identifikaci trendů, vzorců nebo sezónních změn, a představují základní nástroj pro analýzu časových dat. (Box et al., 2016, s. 21)

2.4.1 Diskrétní deterministické a statistické časové řady

Diskrétní časové řady mohou vznikat dvěma způsoby. Prvním je vzorkování kontinuální časové řady, například měření vstupu a výstupu z plynového kotle každých 9 sekund, jak je znázorněno na obrázku 1.2. Druhým způsobem je kumulace hodnot během určitého časového období, jako je například denní či měsíční úhrn srážek, nebo výnos z výrobních dávek, kde každá dávka představuje jeden údaj. Obrázek 2.1 ilustruje časovou

řadu, která ukazuje výnosy z 70 po sobě jdoucích dávek chemického procesu. Tato série je uvedena jako Series F v části pět této práce. (Box et al., 2016, s. 22)

Časové řady mohou být také klasifikovány na základě jejich předvídatelnosti. Pokud lze budoucí hodnoty časové řady přesně určit pomocí matematické funkce, jedná se o deterministickou časovou řadu. Naopak, pokud lze budoucí hodnoty popsat pouze prostřednictvím pravděpodobnostního rozdělení, mluvíme o nedeterministické nebo statistické časové řadě. Výnosy dávkových procesů z obrázku 2.1 jsou příkladem statistické časové řady. Přestože vykazují jasný vzorec vysokých a nízkých hodnot, není možné přesně předpovědět výnos další dávky. Tato práce se zabývá především statistickými časovými řadami. (Box et al., 2016, s. 22)

2.5 Význam a aplikace prediktivní analýzy v různých odvětvích

2.5.1 Prediktivní analýza v obchodu a marketingu

Jak efektivní může být prediktivní analýza pro marketing v různých obchodních sektorech?

Prediktivní analýza se široce uplatňuje zejména v marketingu v sektoru business-to-consumer (B2C), zatímco v business-to-business (B2B) se její využití liší díky odlišné povaze rozhodovacích procesů. V B2B sektoru obvykle rozhodují nákupčí nebo manažeři, kteří jednají jménem uživatelů, což činí proces složitějším a zdlouhavějším. Analytika v tomto prostředí hraje klíčovou roli při identifikaci rozhodovacích osob, jejich pozic a charakteristik firem, například odvětví, velikosti, obratu či počtu zaměstnanců. (Leventhal, 2018, s. 177)

Techniky analýzy jako modelování potenciálních zákazníků (prospect modeling) a hodnocení příležitostí (lead scoring) pomáhají cílit na firmy s nejvyšším potenciálem a upřednostňovat kontakty. Přestože techniky používané v B2C mohou být aplikovány i v B2B, studie z roku 2016 naznačuje, že většina B2B firem plně nevyužívá dostupná data, přičemž prediktivní analýza je jednou z nejslabších oblastí. (Leventhal, 2018, s. 177)

Existuje však mnoho potenciálních aplikací prediktivní analýzy v B2B, včetně segmentace zákazníků, analýzy podílu na trhu a modelování ztrát zákazníků. Firmy mohou

být segmentovány na velké korporace, malé a střední podniky (SMEs) a malé kanceláře či domácí kanceláře (SOHOs), přičemž každá z těchto skupin má své specifické potřeby a obchodní příležitosti. Statistiky například ukazují, že zatímco korporace tvoří pouhých 0,1 % podniků, generují 53 % celkového obrátu, zatímco SOHOs, ačkoliv představují 96 % podniků, přispívají méně než 20 % k celkovému obrátu. (Leventhal, 2018, s. 177)

Tyto nerovnováhy ukazují, jak je důležité cílit strategii na konkrétní segmenty a aplikovat prediktivní analýzu na podporu růstu a optimalizace procesů. Přestože B2B sektor dosud plně nevyužil svůj potenciál v této oblasti, rozvoj těchto technologií přináší obrovské příležitosti.

V marketingu je prediktivní analýza většinou zaměřena na zákazníky – tento předpoklad bude také základem následujícího textu, pokud nebude uvedeno jinak. Můžeme ji aplikovat například na (Leventhal, 2018, s. 6):

1. Potenciální zákazníci nebo lidi, kteří ještě nejsou vašimi zákazníky
2. Vyřazené nebo ztracené zákazníky, které byste mohli chtít získat zpět.
3. Podniky, včetně korporací, velkých společností, malých a středních podniků (MSP).
4. Předplatitelé, např. telefonní společnosti nebo kabelové televize.
5. Účty, např. banky nebo stavební spořitelny.
6. Nákupní košíky nebo transakce v maloobchodě.
7. Občané, např. obyvatelé místní samosprávy.
8. Majetek, např. automobily pořízené vašimi zákazníky.
9. Počítače a zařízení, jako jsou mobilní telefony a tablety.
10. Stroje a zařízení připojené k internetu věcí (IoT).
11. Geografické oblasti, jako jsou výstupní oblasti sčítání lidu.

2.5.2 Prediktivní analýza v medicíně

Skutečný přínos technologií, jako jsou umělá inteligence, strojové učení, zpracování přirozeného jazyka, robotika a data, spočívá v přechodu od tradičního modelu poplatků za služby k preventivní medicíně. Místo toho, abychom čekali, až lidé onemocní, a následně

léčili jejich příznaky, můžeme předem identifikovat zdravotní rizika a přijmout opatření k jejich prevenci. Přestože tento přístup může znamenat vyšší počáteční náklady, dlouhodobě by mohl zdravotnictví ušetřit značné finanční prostředky. (Fombu, 2020, s. 177)

Prediktivní medicína, která se zaměřuje na odhadování budoucích zdravotních rizik pomocí analýzy velkých objemů dat, se přirozeně propojuje s preventivní medicínou, která na základě těchto předpovědí podniká kroky k prevenci nemocí. Technologie, jako je genetické testování, umožňují identifikovat potenciální zdravotní problémy ještě předtím, než se objeví příznaky, někdy dokonce již u nenarozených dětí. To umožňuje přijímat preventivní opatření a měnit chování s cílem minimalizovat rizika. (Fombu, 2020, s. 177)

Cílem prediktivní medicíny je spolupráce lékařů a pacientů při snižování pravděpodobnosti budoucích zdravotních problémů. Například lidé s vyšším rizikem srdečních onemocnění mohou častěji podstupovat EKG nebo konzultace s kardiology. Tento přístup slouží jak zdravým lidem, tak pacientům s již existujícími nemocemi, přičemž hlavním cílem je zlepšení kvality života prostřednictvím včasné predikce a prevence. (Fombu, 2020, s. 177)

2.5.3 Prediktivní analýza v průmyslu

V průmyslovém prostředí hrají data zásadní roli. Firmy shromažďují rozsáhlé množství informací z výrobních zařízení, senzorů a dodavatelských řetězců. Tyto údaje slouží jako základ pro prediktivní modely, které mohou identifikovat potenciální problémy a navrhnout preventivní opatření. Mezi klíčové aplikace patří například prediktivní údržba, která umožňuje včasné odhalení poruch a zamezení výpadků, optimalizace výrobních procesů a přesnější řízení dodavatelských řetězců. (Sapra, 2025)

Technologie využívané pro prediktivní analýzu zahrnují systémy pro analýzu velkých dat, strojové učení nebo internet věcí (IoT). Tyto nástroje umožňují efektivnější práci s daty a poskytují podnikům konkurenční výhodu. Například prediktivní údržba nejen snižuje náklady, ale také zvyšuje produktivitu a zlepšuje celkovou spolehlivost provozu. (Sapra, 2025)

Kromě přínosů existují i výzvy, které s sebou prediktivní analýza přináší. Implementace nových technologií vyžaduje kvalitní data a překonání odporu ke změnám uvnitř organizací. Přesto však budoucnost prediktivní analýzy v průmyslu slibuje nové příležitosti, jak zlepšit

procesy, snížit náklady a maximalizovat efektivitu. S rozvojem technologií se její význam pro průmyslové podniky stává stále zásadnější. (Sapra, 2025)

2.6 Data mining

Data mining je často charakterizován jako proces hledání skrytých informací v databázích. Tento přístup je také známý jako průzkumná analýza dat, datové objevování nebo deduktivní učení. Jeho hlavním cílem je odhalit cenné poznatky, které mohou být použity pro predikci, rozhodování či optimalizaci různých procesů. (Leventhal, 2018, s. 23)

Tradiční databázové dotazy využívají přesně definované požadavky, například v jazyce SQL, k vyhledávání dat odpovídajících zadaným kritériím. Výsledkem těchto dotazů může být podmnožina databáze, extrahovaný pohled nebo agregované informace. Data mining však přistupuje k databázím odlišně:

- Dotazy: V rámci procesu dolování dat nemusí být dotaz jasně formulován ani specifikován. Data miner si nemusí být zcela jistý, jaké konkrétní informace hledá.
- Data: Na rozdíl od provozní databáze se často pracuje s verzí dat, která byla upravena a vyčištěna tak, aby lépe vyhovovala analytickým potřebám.
- Výstupy: Výsledkem dolování dat zpravidla není podmnožina databáze, nýbrž hlubší analýza jejího obsahu, která umožňuje odhalit zajímavé poznatky nebo vzorce. (Leventhal, 2018, s. 23)

2.7 Řízení dat pro účely prediktivní analýzy

Úspěšnost prediktivní analýzy ve firmě závisí především na dostupných datech o zákaznících. Kvalitní a vhodná data jsou důležitější než samotná volba složitých modelovacích technik. Analytik se proto zaměří na to, aby z dat získal maximální přínos, což zahrnuje identifikaci relevantních typů a zdrojů informací, detailní pochopení jejich obsahu a vytvoření smysluplného souboru proměnných. (Leventhal, 2018, s. 35)

- Identifikace zdrojů dat, které jsou klíčové pro prediktivní analýzu, a určení jejich dostupnosti.

- Prozkoumání různých typů dat, se kterými je možné se při analýze setkat.
- Využití datového auditu jako nástroje k hodnocení kvality dostupných dat.
- Stanovení hlavních kroků přípravy dat, zahrnující vytvoření analytické datové sady pro proces dolování dat.

2.8 Jakou roli mají data?

- Vývojová role
- Role nasazení
- Popisující role

2.8.1 Vývojová role

Během fáze modelování dat se analyzuje velké množství atributů, známých také jako proměnné nebo pole, a pro vytvoření analytického modelu se vybírají ty s nejvyšší prediktivní hodnotou. Důležitým předpokladem je, aby tyto proměnné byly dostupné a konzistentně kódované napříč celou databází zákazníků. U velkých společností, které obvykle mají miliony klientů, se pro vývoj modelu často používá reprezentativní vzorek dat. Pro každého zákazníka však mohou být uloženy stovky či tisíce proměnných, což vede k označení vývojového souboru dat jako „krátký a široký“ – „krátký“ díky menšímu počtu zákazníků ve vzorku a „široký“ díky velkému počtu zahrnutých proměnných (Leventhal, 2018, s. 36)

2.8.2 Role nasazení

Po vytvoření a otestování modelu je při jeho aplikaci na celou zákaznickou základnu nutné zhodnotit u každého zákazníka sadu prediktivních proměnných, které byly použity při sestavování modelu. Je důležité zajistit, aby byly tyto proměnné dostupné a konzistentně kódovány, stejně jako v původním vývojovém vzorku. Pro tuto fázi se obvykle využívá datová sada označovaná jako „vysoká a úzká“ – „vysoká“ kvůli zahrnutí záznamů všech zákazníků a „úzká“, protože obsahuje relativně malé množství proměnných použitých v modelu. (Leventhal, 2018, s. 36)

2.8.3 Popisující role

Třetí úkol spočívá v použití dat k vytvoření profilů zákazníků, kteří byli modelem přiřazeni do jednotlivých bodových pásem nebo segmentů. Tento krok je důležitý pro lepší porozumění těmto segmentům, ověření jejich logiky z obchodního hlediska a definování strategií pro jejich oslovení na trhu. Proces popisu segmentů hraje klíčovou roli při tvorbě systému zákaznické segmentace, přičemž jeho výsledkem jsou detailní profily a smysluplné názvy jednotlivých segmentů. (Leventhal, 2018, s. 37)

Pro tento účel lze využívat data z průzkumů nebo z databáze zákazníků, přičemž informace slouží výhradně pro popisné účely. Popisný soubor dat se může lišit podle svého zdroje – může být „nízký“ nebo „vysoký“ a zároveň „široký“ nebo „úzký“. Například průzkum spokojenosti může poskytovat širokou škálu informací od malého vzorku zákazníků, zatímco data o internetovém chování mohou zahrnovat omezený počet proměnných, ale pokrývat velký podíl zákazníků. (Leventhal, 2018, s. 37)

2.9 Jak jsou data užitečná pro prediktivní analýzu v logistice?

Je tedy jasné, jak data fungují, ale jak to je s daty v prediktivní analýze? Data představují základní stavební kámen prediktivní analýzy, protože umožňují vytvoření modelů, které přinášejí užitečné předpovědi a zefektivňují rozhodovací procesy. Díky datům lze identifikovat vzorce, trendy a souvislosti, jež jsou klíčové pro pochopení minulého i budoucího chování, ať už jde o zákazníky, trhy nebo procesy. Kvalitní a relevantní data jsou zásadní pro přesnost modelů a minimalizaci chyb, zatímco špatně strukturovaná nebo nekonzistentní data mohou vést k nesprávným závěrům.

Data využívaná pro prediktivní analýzu mohou zahrnovat různé oblasti. Například demografická data slouží k segmentaci zákazníků, zatímco transakční a behaviorální data umožňují lépe pochopit zákaznické chování. Externí data, jako jsou informace o tržních trendech nebo makroekonomických ukazatelích, rozšiřují možnosti analýzy a umožňují zohlednit širší kontext. (Bhatia, 2019, s. 24)

Správné zpracování a příprava dat jsou pro prediktivní analýzu klíčové. Tento proces zahrnuje čištění dat od chyb a duplicit, transformaci dat do vhodného formátu, výběr relevantních proměnných a jejich integraci do jednoho konzistentního souboru. Kromě toho

je důležité provést validaci dat, která zajistí, že jsou vhodná pro použití v modelech. (Bhatia, 2019, s. 24)

Díky prediktivní analýze mohou firmy například předpovídat chování zákazníků, plánovat kapacity, optimalizovat marketingové kampaně nebo efektivněji alokovat zdroje. Představuje tak nedílnou součást moderního rozhodování, jež je založeno na datech. Zároveň je nutné si uvědomit, že efektivita prediktivní analýzy vždy závisí na kvalitě a dostupnosti vstupních dat. Správný výběr, příprava a pochopení dat jsou proto nezbytné pro úspěšné výsledky.

V logistice mimo jiné, jsou data nepostradatelným nástrojem pro zajištění efektivního plánování a řízení procesů. Na základě historických dat lze přesněji odhadnout poptávku, což usnadňuje optimalizaci skladových kapacit i dopravy. Data zároveň pomáhají při plánování tras zásilek, snižování nákladů na přepravu a řešení problémů, jako jsou zpoždění či výpadky dodávek.

Prediktivní modely umožňují předem identifikovat rizika v dodavatelském řetězci a zajistit, že na ně firma dokáže včas reagovat. Spojení historických dat s daty v reálném čase zvyšuje flexibilitu řízení, což vede ke snížení nákladů, zlepšení procesů a vyšší spokojenosti zákazníků. Tento přístup tak zásadně přispívá k celkové efektivitě logistických operací.

2.10 Jak důležité je, mít k dispozici správná data?

Bez ohledu na množství dostupných datových položek a jejich schopnost popsat zákaznickou základnu je zásadní zajistit, aby data byla vhodná pro účely prediktivní analýzy. To znamená, že musí obsahovat reprezentativní příklady pokrývající všechny možné výsledky, které má model předpovídat, na což je ideální tzv. data audit, který má za úkol prověřit atributy v datové sadě. Pouze tak lze zaručit, že model bude schopný poskytovat spolehlivé předpovědi napříč různými scénáři. Rozdělme si data tedy do dvou skupin:

- Strukturovaná data.
- Nestrukturovaná data. (Nelson, 2020)

2.10.1 Strukturovaná data

Strukturovaná data se ukládají v tabulkách, například v souborech Excel nebo databázích SQL. Tyto tabulky jsou uspořádány do řádků a sloupců, kde každý sloupec představuje určitou proměnnou a každý řádek jeden záznam. Díky této organizaci lze snadno porozumět vztahům mezi různými hodnotami.

Strukturovaná data mohou obsahovat informace, jako jsou jména, adresy, data, čísla kreditních karet nebo dokonce multimediální obsah, jako jsou obrázky či zvuky. Mezi jejich zdroje patří například senzory, síťové logy nebo data z maloobchodních systémů. Také lze vytvářet ručně, například při vyplňování formulářů. Tímto způsobem získaná data se automaticky ukládají do strukturované podoby pro snadné využití a analýzu. (Nelson, 2020)

2.10.2 Nestrukturovaná data

Nestrukturovaná data nejsou uspořádána podle žádného pevného modelu nebo struktury. To znamená, že je nelze analyzovat tradičními způsoby, které se využívají pro zpracování strukturovaných dat. Často se označují jako kvalitativní data a vyžadují jiné metody pro analýzu.

Protože mezi jednotlivými prvky nestrukturovaných dat nejsou jasné vztahy, nelze je uložit do běžných relačních databází. Vhodným způsobem ukládání jsou například nerelační databáze NoSQL nebo datová jezera, která umožňují uchovávat velké množství nestrukturovaných dat. Analýza těchto dat je náročnější, protože je nutné jednotlivé části podrobně zkoumat a hledat vzory nebo funkce, které se v nich opakují.

Nestrukturovaná data tvoří převážnou většinu dat, přibližně 80 %. Příkladem mohou být texty, obrázky, videa nebo zvukové nahrávky. Přestože je jejich zpracování složitější, obsahují cenné informace, které mohou být užitečné pro další analýzu a rozhodování. (Nelson, 2020)

2.11 Příprava dat

Proces přípravy dat začíná výběrem vhodných zdrojů, které budou podrobeny podrobné analýze, a jejich následnou transformací do formátu, který je možné efektivně využít. Tato fáze zahrnuje několik důležitých kroků nezbytných pro úspěch projektů

zaměřených na dolování dat. Podle odhadů tvoří příprava dat až 60-70 % celkového úsilí, které je do těchto projektů investováno. Tento časový nárok přetrvává i v případech, kdy data pocházejí z dobře spravovaných databází, protože kombinování informací z různých systémů nebo oprava chyb může zvýšit náročnost práce. Obdobně i začlenění historických dat z archivů může celý proces dále komplikovat a vyžadovat více času a zdrojů. (Leventhal, 2018, s. 50)

Při sestavování analytického datového souboru (ADS) je nezbytné vycházet jak z pochopení daného obchodního problému, tak z analýzy dostupných datových zdrojů. ADS má zásadní vliv na modelovací proces a hodnocení výsledků, a proto by jeho návrh měl být důkladně promyšlen. Tento návrh by měl obsahovat následující klíčové aspekty:

- Definování analyzovaných jednotek: Jako jsou například účty, předplatitelé nebo nákupní košíky.
 - Vymezení modelového prostoru: Stanovení celkové oblasti, kterou model pokrývá.
 - Určení časového rámce: Specifikace období, na které se analýza zaměřuje.
 - Nastavení cílové proměnné: Jasná definice výsledku, který má model předpovědět, a výběr příslušných prediktorů, které budou zahrnuty.
 - Integrace a úprava zdrojů dat: Popis způsobů, jak data restrukturovat a slučovat pro analytické potřeby.
 - Odvození nových proměnných: Vytváření dalších proměnných na základě stávajících dat.
 - Řešení chybějících hodnot: Stanovení postupů pro práci s neúplnými nebo nulovými údaji.
- (Leventhal, 2018, s. 51)

2.12 Predikce chování zákazníků

Cesta zákazníka představuje sled interakcí mezi zákazníkem a firmou – od prvního seznámení se s produkty až po případný odchod. Tento proces je jedinečný pro každého zákazníka a může být velmi komplexní. Firmy často mapují jednotlivé kroky této cesty, aby mohly identifikovat oblasti ke zlepšení. Výsledkem je větší spokojenost zákazníků, jejich loajalita, vyšší objem nákupů a zvýšení ziskovosti.

Prediktivní analýza hraje klíčovou roli při optimalizaci zákaznické cesty. Firmám umožňuje zaměřit zdroje na zásadní fáze – od cíleného získávání zákazníků, přes nabídky dodatečných produktů (cross-selling a up-selling), až po prevenci jejich odchodu. Například retenční modely dokážou rozpoznat zákazníky s vysokým rizikem odchodu a umožní vytvořit nabídky, které je motivují zůstat. Podobně win-back modely pomáhají opětovně získat ztracené zákazníky, pokud jejich návrat přinese firmě zisk. (Leventhal, 2018, s. 100)

Úspěch prediktivních modelů však závisí na jasně stanovených obchodních požadavcích. Ty zahrnují například určení cílových produktů nebo zákaznických skupin, způsob doručování nabídek (např. e-mailem či online) nebo formát výsledků modelu. Důležité je také zajistit hladkou integraci modelů do stávajících procesů, což maximalizuje jejich přínos a zajišťuje efektivní využití. (Abbott, 2014, s. 239)

Prediktivní analýza přináší firmám výhodu nejen v porozumění zákaznickému chování, ale také v zefektivnění rozhodovacích procesů. Tím pomáhá firmám budovat dlouhodobé vztahy se zákazníky a dosahovat lepších obchodních výsledků. (Abbott, 2014, s. 239)

2.12.1 Chování spotřebitelů a Big dat

Analýza spotřebitelského chování, která zahrnuje posouzení charakteristik zákazníků prostřednictvím různých faktorů, je nezbytnou součástí strategie malých i velkých podniků. K zajištění úspěchu je nutné, aby každá firma jasně definovala svůj cílový trh a zaměřila se na klíčové aspekty, které tento trh charakterizují. Důležité proměnné zahrnují demografické údaje, psychografické faktory a vzorce chování zákazníků. Tyto proměnné umožňují přesněji predikovat chování zákazníků a zlepšit rozhodování založené na datech v reálném čase. (Liu, 2023, s. 1056)

Velká data jsou klíčovým nástrojem pro hlubší pochopení zákaznických trendů, jako jsou nákupní zvyklosti, příjmové skupiny, vliv věrnostních programů či obchodní cykly. Tento typ analýzy umožňuje firmám identifikovat klíčové faktory ovlivňující spotřebitelské rozhodování a přizpůsobit nabídku konkrétním potřebám zákazníků. Využití datových modelů a pokročilé analýzy tak firmám poskytuje konkurenční výhodu. (Liu, 2023, s. 1056)

Moderní přístupy k analýze spotřebitelského chování zahrnují využití online nástrojů, jako jsou Google či Facebook, které zásadně změnilы interakci mezi firmami a zákazníky. Díky těmto datům jsou firmy schopny přesněji porozumět trhu, na kterém působí,

a přizpůsobit své výrobní a marketingové strategie aktuálním zákaznickým preferencím. Tímto způsobem si nejen upevňují vztahy se zákazníky, ale také zvyšují svou konkurenceschopnost na trhu. (Liu, 2023, s. 1056)

2.12.2 Faktory ovlivňující chování spotřebitelů

Na spotřebitelské chování působí celá řada faktorů, které závisí na specifikách jednotlivých trhů. Mezi zásadní vlivy lze zařadit psychologické, sociální, kulturní, osobní a ekonomické aspekty, které dohromady utvářejí rozhodovací proces zákazníků. Integrace těchto faktorů do analýzy spotřebitelského chování je klíčová pro pochopení trhu a úspěšnou implementaci obchodních strategií. Moderní technologie, zejména analýza velkých dat, umožňují firmám efektivně sledovat změny v preferencích zákazníků a přizpůsobovat se dynamickým tržním podmínkám. (Liu, 2023, s.1056)

2.12.2.1 Psychologické faktory

Psychologické vlastnosti jednotlivce zásadně ovlivňují jeho nákupní chování. Zásadní roli zde hraje motivace, vnímání, přesvědčení a postoje. Tyto charakteristiky umožňují firmám analyzovat vzorce chování zákazníků a identifikovat důležité trendy, což je nezbytné pro přizpůsobení jejich obchodních strategií. Analýza big dat slouží jako klíčový nástroj k pochopení těchto vlivů. (Liu, 2023, s.1056)

2.12.2.2 Sociální faktory

Sociální prostředí zákazníků, zahrnující vliv rodiny, sociálních skupin, rolí a společenského postavení, zásadně formuje jejich preference. Tyto faktory určují, jaké produkty jsou pro zákazníky atraktivní, a zároveň ovlivňují způsob propagace a cenové strategie firem. Pochopení těchto vlivů umožňuje firmám optimalizovat jejich přístup k zákazníkům. (Liu, 2023, s.1056)

2.12.2.3 Kulturní faktory

Kultura, která je úzce propojena se společenskými hodnotami, hraje důležitou roli v nákupním chování spotřebitelů. Zvykové vzorce a kulturní přesvědčení ovlivňují nejen výběr produktů, ale také způsob, jakým zákazníci přistupují k procesu nákupu. Firmy, které ignorují kulturní specifika, riskují neúspěch na daném trhu. (Liu, 2023, s.1056–1057)

2.12.2.4 Osobní faktory

Individuální charakteristiky, jako je věk, příjem, povolání a životní styl, definují, jaké produkty jsou pro zákazníky atraktivní. Například věkové skupiny se výrazně liší ve svých preferencích, zatímco příjem a pracovní zařazení ovlivňují jejich kupní sílu. Zohlednění těchto vlastností pomáhá firmám efektivně cílit na specifické segmenty trhu. (Liu, 2023, s.1057)

2.12.2.5 Ekonomické faktory

Hospodářské podmínky, například ekonomická situace, míra inflace či nezaměstnanosti, přímo ovlivňují schopnost zákazníků nakupovat. Při příznivých ekonomických okolnostech mají zákazníci větší kupní sílu, což motivuje firmy ke zvýšení nabídky produktů a služeb. (Liu, 2023, s.1057)

2.13 Prediktivní poptávky

Prediktivní poptávky představují metodu, která se zaměřuje na odhad budoucích potřeb na základě analýzy dostupných historických dat a aktuálních trendů. Tento přístup umožňuje podnikům lépe plánovat své aktivity, snižovat provozní náklady a zároveň zvyšovat efektivitu procesů. Výsledkem je nejen vyšší zisk, ale také kvalitnější služby pro zákazníky. (Gangur, 2015, s. 27)

2.13.1 Technologie a metody

Pro dosažení přesných předpovědí se využívají různé moderní metody a technologie, například:

- Algoritmy umělé inteligence: Tyto algoritmy analyzují rozsáhlé datové sady a hledají v nich vzorce, které napomáhají přesným predikcím.
- Statistické modely: Techniky jako regrese či analýza časových řad pomáhají identifikovat klíčové faktory ovlivňující poptávku.
- Analýza velkých dat: Zpracování dat z různých zdrojů, jako jsou interní záznamy, trendy na trhu či sociální média, poskytuje široký kontext pro rozhodování.
- Simulace scénářů: Pomocí simulace lze testovat různé hypotetické situace, jako jsou změny v chování trhu nebo sezónní výkyvy. (Gangur, 2015, s. 27)

2.13.2 Oblasti využití

Prediktivní poptávky mají široké uplatnění v různých průmyslových odvětvích:

- Obchod: Napomáhají optimalizaci skladových zásob tím, že předpovídají, které produkty budou v dané době nejžádanější.
- Výrobní procesy: Přesnější plánování kapacit výroby eliminuje riziko nadbytku nebo nedostatku.
- Logistika: Podniky mohou efektivněji plánovat trasy a nasazovat dopravní prostředky podle očekávaného objemu zakázek.
- Marketingové kampaně: Predikce chování zákazníků umožňuje správně načasovat a zacílit reklamní strategie. (Gangur, 2015, s. 28–29)

2.13.3 Výhody a výzvy

Mezi hlavní přínosy prediktivních poptávek patří:

- Snížení nákladů díky optimalizaci procesů.
- Zajištění vyšší dostupnosti produktů a služeb.
- Konkurenční výhoda díky schopnosti rychle reagovat na změny trhu. (Gangur, 2015, s. 29)

Ovšem i tento přístup má své výzvy, například:

- Závislost na kvalitních datech – nedostatečná nebo neúplná data mohou snižovat přesnost předpovědí.
- Nákladná implementace pokročilých analytických nástrojů.
- Nepředvídatelné faktory, jako jsou změny v ekonomice nebo chování zákazníků. (Gangur, 2015, s. 29)

2.14 Plánování přepravních cest

Historie dopravy ukazuje, jak klíčovou roli hrála mobilita při ekonomickém růstu, propojení regionů a sdílení kultur. Od dávných cest, jako byla Hedvábná stezka, která spojovala Čínu s římskou říší, přes rozsáhlou síť římských silnic, až po moderní vodní, železniční a automobilové trasy, doprava vždy významně formovala lidskou společnost. Během průmyslové revoluce hrála vodní doprava zásadní roli díky nízkým nákladům a ekologickým výhodám. (Teodorović, 2016, s. 1-2)

Plánování přepravních cest je dnes komplexním procesem, který zahrnuje návrh dopravní infrastruktury, řízení toků a optimalizaci systémů. Využívá se kombinace technologií, matematických metod a operačního výzkumu k dosažení vyšší kapacity, bezpečnosti a spolehlivosti dopravních sítí. Tyto přístupy pomáhají řešit problémy, jako je synchronizace jízdnic, návrh tras a snižování dopravní zácpy. (Teodorović, 2016, s. 1-2)

Logistika a řízení dodavatelského řetězce (SCM) jsou zásadní pro efektivní správu výrobních a servisních systémů. Logistika koordinuje tok materiálů od výrobců k spotřebitelům a zpětný tok informací od zákazníků k dodavatelům, čímž zajišťuje efektivitu a kvalitu procesů. SCM propojuje klíčové obchodní procesy mezi dodavateli a zákazníky, čímž přináší hodnotu všem zúčastněným stranám. Moderní logistické systémy kladou důraz na bezpečnost, udržitelnost a kvalitu, čímž čelí komplexním výzvám dnešního prostředí.

2.14.1 Plánování dodavatelského řetězce

Plánování dodavatelského řetězce zahrnuje tři hlavní úrovně rozhodování:

- Strategickou,
- taktickou,
- operační.

Strategická úroveň se zaměřuje na konfiguraci logistické infrastruktury, což zahrnuje umístění a výstavbu výrobních a distribučních uzlů s ohledem na kapacitu, náklady a vybavení. Taktická a operační rozhodnutí zahrnují například řízení zásob, pravidla pro objednávání zboží, manipulaci se skladovanými produkty, plánování dodávek a distribuční strategie uvnitř řetězce.

Moderní přístupy k dodavatelskému řetězci zdůrazňují potřebu integrovat nákladové faktory na všech třech úrovních, což umožňuje komplexní a efektivní rozhodování. Tato integrace je zásadní pro řešení logistických výzev a podporu řízení v průmyslových a servisních sektorech. Klíčové aspekty zahrnují výběr dodavatelů, umístění výrobních zařízení, konfiguraci distribuční sítě, rozhodování o způsobech dopravy a plánování tras pro efektivní zásobování zákazníků.

2.14.2 Problémy a otázky

Logistika a řízení dodavatelského řetězce (SCM) zahrnují problémy na strategické, taktické a operační úrovni, které čelí vysoké komplexitě. Klíčové aspekty zahrnují koordinaci v víceúrovňových výrobních systémech, správu velkého počtu produktů, například v automobilovém průmyslu, a manipulaci s produkty ve skladovacích procesech. Potravinářský průmysl řeší zboží podléhající zkáze s důrazem na kvalitu a bezpečnost. Dále se uplatňuje logistický outsourcing, propojení přímých a nepřímých toků materiálů, využití různých balicích technologií, zohlednění ekologického dopadu a kombinace více dopravních módů, jako jsou silniční, železniční, námořní a letecká doprava. Moderní logistika se opírá o metody, jako je lineární programování nebo heuristické algoritmy, pro optimalizaci rozhodování na všech úrovních.


2.14.3 Plánování a rozvrhování výroby

Logistika a řízení dodavatelského řetězce zahrnují složité problémy na strategické, taktické a operační úrovni. Klíčové aspekty zahrnují koordinaci v globálních výrobních systémech, správu velkého množství produktů, manipulaci a skladování, řízení zásob zboží podléhajícího zkáze, outsourcing logistických služeb, integraci přímých a nepřímých toků materiálů, využití různých balicích technologií a více druhů dopravy. Důležitou součástí je také posuzování environmentálních dopadů a využívání pokročilých metod, jako je lineární programování či heuristické algoritmy, pro optimalizaci rozhodování a efektivitu systémů.

2.14.4 Návrh logistických sítí

Návrh logistických sítí hraje klíčovou roli v potravinářském dodavatelském řetězci, zvláště při manipulaci s produkty s omezenou trvanlivostí. Přeprava těchto produktů je složitá a nákladná, přičemž logistický manažer musí zajistit kontrolu klíčových fází procesu a minimalizovat ztrátu trvanlivosti, aby byla zachována kvalita od výroby až po spotřebitele – tedy „z farmy na stůl“. (Kumar, 2021, s. 3)

Obrázek 3. znázorňuje dvě konfigurace distribuční sítě pro čerstvé produkty. AS-IS konfigurace ukazuje stávající systém, který zahrnuje dodavatele, regionální distribuční centra (RDC) a obchodní jednotky, jako jsou obchody a nákupní centra, a zahrnuje dvě fáze: dodavatelé–RDC a RDC–obchodní jednotky s přibližně 20 RDC. (Kumar, 2021, s. 3)



Obrázek 3: Distribuční sítě pro čerstvé produkty (Kumar, 2021, s. 3)

2.15 Predikce a minimalizace logistických rizik

Podniky jsou vystaveny rizikům, která mohou vést ke ztrátám, především pokud jejich procesy nejsou dostatečně odolné vůči různým hrozbám. Tyto hrozby lze rozdělit na vnější, které jsou nezávislé na podniku a vnitřní, jež vyplývají z jeho činností. Nejistoty spojené s oběma typy rizik nelze zcela eliminovat, ale jejich dopady lze výrazně zmírnit správnými preventivními opatřeními. Komplexita podnikových procesů zároveň zvyšuje pravděpodobnost negativního vlivu rizik na výkon logistiky. (Kumar, 2021, s. 4)

V současném globálním prostředí podniky často rozšiřují svou působnost do zahraničí, aby uspokojily zákazníky na místních trzích. Tento přístup však přirozeně prodlužuje logistické procesy a přidává nové úkoly. Jakékoliv narušení v jednom bodě logistického toku může ovlivnit celkovou výkonnost systému. Složitost logistiky je také úzce propojena s obchodními vztahy s partnery a implementací podnikových strategií. Například při „štíhlé výrobě“ je cílem co nejvíce snížit náklady na zásoby, zatímco strategie rychlé reakce vyžaduje určitou úroveň zásob pro dosažení požadovaných výsledků. Důkladné plánování logistických aktivit a efektivní organizace jsou nezbytné pro minimalizaci dopadů narušení. (Kumar, 2021, s. 4)

2.15.1 Risk management

V poslední době se pozornost stále více zaměřuje na řízení rizik, zejména kvůli narušujícím událostem, jako jsou zemětřesení, erupce islandské sopky, rostoucí mzdy v Číně nebo únik ropy společnosti BP. Tyto situace mohou mít dopad na podnikové operace a často vyžadují přizpůsobení logistických systémů. Připravený plán může podnikům pomoci účinně zvládat dopady těchto neočekávaných událostí. (Kumar, 2021, s. 9)

Řízení rizik je možné rozdělit do dvou přístupů: strategie prevence a strategie řešení důsledků. Prevence se zaměřuje na eliminaci nebo zmírnění zdrojů rizik, zatímco řešení důsledků je orientováno na zvládání a minimalizaci dopadů již vzniklých rizik. Oba přístupy dohromady poskytují základní nástroje pro zajištění stability a odolnosti podnikových procesů. (Kumar, 2021, s. 9)

Riziko představuje pravděpodobnost vzniku škod nebo ztrát na příjmech, kterou lze přesně vypočítat. Díky tomu je možné předvídat rizikové události a aplikovat kontrolní metody, které je buď eliminují, nebo minimalizují jejich důsledky. (Kumar, 2021, s. 10)

Identifikace rizik se váže na různé prvky logistických systémů a procesů. Interní rizika souvisejí s regionálními zásobovacími systémy a procesy orientovanými na soběstačnost. Mezi jejich hlavní příčiny patří:

- Pokles plánovaného objemu dopravy nebo přepravní kapacity,
 - Navýšení nákladů na přepravní služby, ať už pro základní či sekundární potřeby,
 - Zvýšení jízdného a daní v regionálních dopravních systémech,
 - Pokles poptávky po dopravě vlivem nižších příjmů domácností a podniků.
- (Kumar, 2021, s. 10)

Zpoždění může vést k porušení dodacích podmínek, jako jsou množství, kvalita nebo dodací lhůta. V oblasti obchodu jsou rizika spojena s přepravou a obchodem, přičemž integrovaný dopravní systém může přispět ke zmírnění těchto problémů. (Kumar, 2021, s. 10)

Nejistoty vznikají, když se pracuje s logistickými podmínkami, jako „přesně včas“, „nejnižší náklady“, „požadovaná kvalita“ či „potřebné množství“. Howardova kostka modeluje nejistotu a zahrnuje tři její dimenze, přičemž logistické řízení by mělo zohledňovat i další faktory. (Kumar, 2021, s. 10)

Rizika lze klasifikovat podle:

- Typu systému (mikrologistická a makrologistická rizika),
 - Druhu logistického toku (rizika spojená s materiálem, financemi, informacemi a personálem),
 - Operací v logistice (nákup, přeprava, výroba, distribuce, skladování a služby).
- (Kumar, 2021, s. 10)

2.15.2 Pět kroků řízení rizik

Proces řízení rizik je základní součástí každé organizace, kterou lze rozdělit na několik klíčových kroků. Prvním z nich je identifikace rizika, což zahrnuje rozpoznání potenciálních hrozeb, které mohou ovlivnit fungování podniku nebo projektů. Tento krok se zaměřuje na analýzu interních a externích faktorů, jež mohou způsobit narušení procesů.

Druhým krokem je analýza rizika, tedy hodnocení pravděpodobnosti jeho výskytu a potenciálního dopadu. Tento krok poskytuje informace o závažnosti rizik, což umožňuje jejich prioritizaci a plánování efektivních opatření. (Kumar, 2021, s. 12)

Následuje hodnocení a prioritizace rizik. Rizika jsou seřazena podle jejich významnosti a naléhavosti, aby se zajistilo, že nejkritičtější hrozby budou řešeny jako první. Tímto způsobem organizace efektivně využívá své zdroje na zmírnění největších problémů. (Kumar, 2021, s. 12)

Čtvrtým krokem je ošetření rizik, které zahrnuje navržení strategií ke zmírnění dopadu, přijetí rizik nebo jejich eliminaci. Tento krok je klíčový pro kontrolu rizik a zajištění stability procesů. (Kumar, 2021, s. 12)

Posledním krokem je sledování a kontrola rizik. Organizace musí pravidelně monitorovat identifikovaná rizika a vyhodnocovat účinnost přijatých opatření. Tímto způsobem může podnik reagovat na nově vzniklá rizika a zajistit kontinuitu svých operací. (Kumar, 2021, s. 12)

Nepřetržité sledování a zlepšování postupů řízení rizik, stejně jako investice do moderních technologií, podporují dlouhodobou udržitelnost a růst podniků. Úspěšné zvládání rizik tak není jen preventivním opatřením, ale strategickým nástrojem, který umožňuje využít výzvy jako příležitosti ke zlepšení procesů, zvýšení efektivity a inovacím.

II PRAKTICKÁ ČÁST

3 PRAKTICKÉ VYUŽITÍ PREDIKTIVNÍ ANALÝZY VE SPOLEČNOSTI IM BENEFIT

3.1 Výběr a popis společnosti

Společnost IM BENEFIT se zaměřuje na stavebnictví a prodej stavebního materiálu, přičemž obě tyto činnosti tvoří pilíře jejího podnikání. Hlavní oblastí působnosti je realizace stavebních zakázek, které zahrnují širokou škálu činností – od výkopových prací až po pokládání střech či výstavbu rodinných domů. Každý projekt začíná konzultací se zákazníkem, během níž jsou specifikovány jeho potřeby a požadavky. Na základě těchto informací se sestaví tým odborníků, který je veden zkušeným vedoucím stavby, aby byl zajištěn hladký průběh všech prací.

Kromě stavební činnosti se firma věnuje také přeprodeji stavebního materiálu, především v menším měřítku. Tato část podnikání zahrnuje dodávku základních materiálů pro menší projekty a individuální zákazníky. Spojení těchto dvou oblastí vytváří unikátní příležitosti i výzvy, zejména v oblasti logistiky a plánování.

V obou těchto oblastech činnosti může prediktivní analýza hrát klíčovou roli. Ve stavebnictví může například pomoci s předpovědí potřeby materiálu, plánováním harmonogramů nebo alokací lidských zdrojů. V oblasti prodeje stavebního materiálu pak může prediktivní analýza podpořit efektivní řízení skladových zásob, předvídání poptávky a optimalizaci dopravy. Díky tomu může společnost lépe reagovat na sezónní výkyvy, snižovat náklady a zároveň zvyšovat spokojenost zákazníků. Efektivní využití prediktivní analýzy tak představuje příležitost k dalšímu růstu a zlepšení procesů napříč celou firmou.

3.2 Analýza dat a implementace prediktivních modelů

Společnost IM BENEFIT se ve své činnosti opírá o efektivní logistické a provozní procesy. Tyto procesy jsou závislé na dostupnosti přesných dat, která mohou být využita k optimalizaci plánování a řízení.

Data potřebná pro analýzu budou získávána z různých interních i externích zdrojů. Mezi interní zdroje patří například integrované informační systémy, které uchovávají informace o zakázkách, nákladech a stavu skladů. Dále budou využívány systémy pro řízení

skladových zásob, které sledují jejich pohyb prostřednictvím technologií, jako jsou čárové kódy. Další důležitou složkou jsou záznamy, kde jsou uvedeny různé činnosti a výkony zaměstnanců.

Externí zdroje zahrnují například údaje o cenách stavebního materiálu, které lze získat prostřednictvím online nástrojů dodavatelů. Kromě toho budou využity informace o povětrnostních podmínkách, které mohou ovlivnit plánování staveb, a také regionální údaje o konkurenci na trhu s materiály.

Data se budou shromažďovat dvěma způsoby: automaticky, například prostřednictvím softwarových systémů, a manuálně tam, kde procesy ještě nejsou digitalizované. Tento kombinovaný přístup zajišťuje, že budou zahrnuta všechna potřebná data.

Aby bylo možné s daty efektivně pracovat, je nutné je sjednotit a ověřit. Všechna data budou centralizována do jednoho systému, což usnadní jejich zpracování. Pokud nebude možné propojení jednotlivých zdrojů, data se ručně upraví do jednotného formátu.

Důležité je také zajistit jejich kvalitu. Přesnost a aktuálnost informací budou ověřovány, aby se minimalizovaly případné chyby. V případech, kdy data obsahují citlivé informace, budou anonymizována pro ochranu soukromí.

Nejdříve tedy dáme data do pořádku, třeba je převedeme do tabulek nebo jednoduchých databází, aby se s nimi lépe pracovalo. Pak se zaměříme na odstranění problémů – chybějící hodnoty, duplicity nebo jiné nedostatky, které by mohly ovlivnit výsledky. A nakonec je upravíme tak, aby byly připravené na použití v modelech. Díky tomuto procesu budeme mít čistá a dobře zpracovaná data, která zajistí spolehlivé výsledky pro analýzy nebo predikce.

Pro zlepšení těchto klíčových aspektů hrají roli vybrané modely prediktivní analýzy, jež umožní společnosti lépe reagovat na proměnlivé podmínky trhu a optimalizovat provoz.

Pro regresní modely:

- Historická data o zakázkách: zahrnují typ projektu (například výkopové práce či výstavbu rodinných domů), jejich velikost, náklady a použité materiály.
- Data o dostupnosti a výkonech pracovníků, včetně záznamů o časové náročnosti jednotlivých činností.
- Finanční údaje spojené s realizací projektů. (Weisberg, 2014, s. 1–2)

Tyto modely jsou užitečné jak ve stavebnictví, tak v oblasti prodeje materiálu. Ve stavebnictví pomohou například s odhadem potřebného množství materiálů pro jednotlivé projekty a výpočtem celkových nákladů zakázky. Tyto predikce budou založeny na údajích, jako je velikost projektu nebo typ činností. V oblasti prodeje stavebního materiálu se regresní modely zaměří na předpovědi objemu prodeje, což umožní efektivněji plánovat skladové zásoby.

Pro časové řady:

- Záznamy o prodeji stavebních materiálů v různých časových obdobích: měsíční nebo roční statistiky, objemy prodeje, druhy materiálů.
- Údaje o změnách skladových zásob, včetně sezónních výkyvů a nárůstů poptávky.
- Historické informace o průběhu zakázek a jejich časových osách. (Box et al., 2016, s. 21)

Analýza časových řad je klíčová zejména při prodeji stavebního materiálu. Na základě historických dat dokážou tyto modely identifikovat sezónní trendy, například zvýšenou poptávku během stavební sezóny nebo pokles v zimních měsících. Ve stavebnictví mohou časové řady pomoci s plánováním pracovní kapacity a stanovením očekávané délky jednotlivých etap projektů.

4 ANALYTICKO-EMPIRICKÁ ČÁST

4.1 Analýza nasbíraných dat

4.1.1 Metodologie sběru dat

Jak byla data ale získávána? Data byla sbírána prostřednictvím kombinace pozorování, rozhovorů a využití interních záznamů společnosti IM BENEFIT. Na sběru dat se přímo podílel majitel firmy, který poskytl celkový přehled o logistických procesech a poptávce po materiálu, a administrativní pracovník odpovědný za skladování a nákup, který sdílel podrobné informace o skladových zásobách a nákupních záznamech.

Proces sběru dat probíhal na základě sepsaných otázek, které byly vytvořeny tak, aby pokryly klíčové aspekty logistických operací, jako jsou skladové zásoby, dodávky materiálu a sezónní výkyvy v poptávce. Během návštěvy skladů byly tyto otázky postupně doplňovány o konkrétní poznatky – například co nejčastěji mizí ze skladu a jaké položky se nejvíce objednávají. Data byla zaznamenávána do nachystaného grafu, který byl průběžně doplňován o údaje z interních tabulek společnosti, jako jsou Excelové soubory se seznamy nákupů a skladových zásob.

4.1.2 Zpracování dat

Pro následnou analýzu bylo klíčové zajistit, aby nasbíraná data byla přesná, spolehlivá a vhodná pro práci s prediktivními modely. Proces zpracování dat zahrnoval několik základních kroků, které zajistily jejich kvalitu a použitelnost.

Nejprve proběhlo očištění dat, při kterém byly záznamy kontrolovány na nesrovnalosti, duplicity a chyby. Nesprávné nebo neúplné hodnoty byly identifikovány a upraveny tak, aby odpovídaly skutečným údajům. Duplicitní záznamy týkající se zakázek a prodejů byly odstraněny, aby nedocházelo k deformaci výsledků analýzy. Následně byla data transformována do jednotného formátu, který usnadnil jejich další zpracování. Jednotky měření, jako jsou tuny, kusy nebo eura, byly standardizovány a číselné hodnoty byly v některých případech převedeny do kategorií, například podle typu materiálu. Tato transformace umožnila propojení dat z různých zdrojů a jejich sjednocení v přehledné tabulky.

Pro ověření správnosti byla provedena validace dat. Každý záznam byl porovnáván s původními zdroji, jako byly ERP systémy, Excelové tabulky poskytnuté společností a ručně zaznamenané poznámky získané během sběru dat. Tento proces zajistil, že všechna data odpovídala realitě a jejich použití v dalších analýzách bylo zcela spolehlivé. V některých případech se spoléhalo ovšem na průměrnou hodnotu více proměnných pro lepší práci s grafy.

Na závěr byla data připravena pro aplikaci statistických metod a modelů. Tento krok zahrnoval spojení několika datových sad, například údajů o skladových zásobách a prodeích, do jedné souhrnné tabulky. Příprava dat zahrnovala i vytvoření vhodných struktur, které odpovídaly požadavkům použitých analytických metod. Tímto postupem byla zajištěna vysoká kvalita a použitelnost dat, která tvoří pevný základ pro další fáze analýzy.

4.1.3 Praktická aplikace regresní analýzy v oblasti stavebních projektů

V praktické části naší analýzy se zaměříme na zjištění vztahu mezi rozpočtem a počtem uskutečněných stavebních činností prostřednictvím lineární regresní analýzy. Naším cílem je zjistit, do jaké míry může rozpočet sloužit jako spolehlivý prediktor počtu realizovaných projektů, což umožní efektivnější plánování stavebních investic.

Začneme prezentací tabulky obsahující různé stavební činnosti, které se vyznačují nižšími finančními náklady, jako například výkopové práce, vymalování, instalace elektrických rozvodů nebo menší rekonstrukce koupelny. Tato tabulka nám poskytne přehled činností, jejich odhadovaných rozpočtů a stručného popisu práce, což bude sloužit jako základ pro naši další analýzu.

Poté aplikujeme regresní analýzu, abychom prozkoumali vztah mezi rozpočtem (nezávislou proměnnou) a počtem realizovaných činností (závislou proměnnou). Na základě této analýzy vytvoříme regresní rovnici, která nám umožní předpovědět počet projektů realizovaných při různých úrovních rozpočtu. Součástí analýzy bude také výpočet koeficientu korelace (R^2), který vyhodnotí spolehlivost modelu.

Činnost	Odhadovaný rozpočet (Kč)	Popis práce
Koupelna	30 000	Menší rekonstrukce (obklady, sanitární zařízení)
Výkopové práce	15 000	Příprava terénu pro základy či kabeláž
Elektrické rozvody	20 000	Instalace či opravy rozvodů
Podlahy	25 000	Pokládka laminátových nebo vinylových podlah
Vymalování	12 000	Malování stěn, drobné opravy omítek
Zateplení	35 000	Izolace menších ploch, např. podkrovní
Fasáda	40 000	Oprava a nový nátěr fasády
Vodoinstalace	18 000	Oprava či rozvody vody
Střecha	50 000	Menší opravy či výměna střešní krytiny
Terénní úpravy	22 000	Úprava zahrady nebo okolí domu
Montáž oken	28 000	Instalace plastových nebo dřevěných oken

Tabulka 1: Přehled menších činností s průměrnými rozpočty a popisem práce (zdroj: vlastní)

Na obrázku jsou znázorněny různé činnosti s přidruženými rozpočty. Tyto rozpočty představují pouze průměrné hodnoty, neboť například při renovaci koupelny se konečná cena může výrazně lišit na základě individuálních požadavků zákazníka. Tabulka navíc z důvodu omezeného prostoru zobrazuje pouze 11 hlavních činností. Později v grafu zahrneme také další aktivity spolu s odhadovanými rozpočty, včetně těch kolem 1 000 Kč. Data mi byla poskytnuta z cca 100 různých kombinací prováděných činností, s kterými se společnost v minulosti setkala v jednom časovém období s určitým možným rozpočtem.

Rozpočet (Kč)	Počet realizovaných prací (ks)
145 000	9
5 000	3
400 000	3
25 000	5
90 000	7
460 000	35
12 000	4
320 000	13
250 000	3
420 000	15
35 000	6


Tabulka 2: Vztah mezi rozpočtem projektu a počtem realizovaných prací (zdroj: vlastní)

Tabulka zobrazuje vztah mezi investovaným rozpočtem a počtem realizovaných prací. Každý řádek představuje konkrétní hodnotu rozpočtu a odpovídající počet prací, které byly za tuto částku realizovány.

Následující graf je histogram znázorňující rozložení počtu realizovaných prací v různých intervalech rozpočtu vycházející z tabulky výše. Účelem této vizualizace bylo zjistit, jak často se jednotlivé rozpočtové kategorie vyskytují a zda existuje nějaký patrný trend v distribuci financovaných prací.

Z grafu lze vyčíst, že většina realizovaných prací spadá do nižších rozpočtových kategorií, zatímco práce s vyššími rozpočty jsou méně časté. Nejnižší interval rozpočtu obsahuje nejvíce případů, což naznačuje, že investice do menších projektů jsou běžnější než do velkých zakázek. Naopak v nejvyšší kategorii rozpočtu se vyskytuje pouze jediný případ, což ukazuje, že velké investice jsou vzácnější.

Na následující graf nyní navážeme analýzou lineární regrese. Cílem této další vizualizace bude zjistit, zda existuje vztah mezi rozpočtem projektu a počtem realizovaných prací. Lineární regrese nám pomůže identifikovat, jak silně spolu tyto dvě proměnné korelují a do jaké míry lze predikovat počet realizovaných prací na základě rozpočtu. Pokud vztah bude dostatečně silný, můžeme jej využít pro budoucí odhady efektivity investic.



Obrázek 4: Rozložení počtu realizovaných prací podle rozpočtu (zdroj: vlastní)

4.1.4 Lineární regrese

Jako první bychom si měli představit, co to vůbec lineární regrese je? Lineární regrese představuje statistickou metodu, která slouží k analýze vztahu mezi dvěma proměnnými. Jednoduchá lineární regrese je jedním z nejčastěji využívaných typů regresní analýzy, která umožňuje vytvářet datové modely pro odhadování hodnot na základě dostupných dat. Typickým příkladem je použití historických dat k predikci budoucích hodnot.

Regresní analýza pracuje s dvěma datovými řadami. První z nich je závislá proměnná (nebo odezвовá proměnná), kterou chceme předvídat, a druhou je nezávislá proměnná (nebo vysvětlující proměnná), která slouží jako základ pro předpověď. Závislá proměnná se zobrazuje na vertikální ose y, zatímco nezávislá proměnná je na horizontální ose x.


Proces zahrnuje vizualizaci dat pomocí bodového grafu, který pomáhá lépe pochopit vztah mezi proměnnými. Na základě datového bodového grafu je následně vytvořena trendová čára, známá jako „čára nejlépe vyhovující“. Tato čára minimalizuje rozdíly mezi skutečnými hodnotami a hodnotami předpovězenými modelem. Jejím cílem je co nejpřesněji reprezentovat vztah mezi proměnnými a umožnit predikci závislé proměnné na základě známé hodnoty nezávislé proměnné.

Matematicky je trendová čára vyjádřena lineární rovnicí

$y = mx + b$, kde:

- m je sklon čáry, který určuje míru změny závislé proměnné při změně jednotkové hodnoty nezávislé proměnné,
- b je průsečík čáry na ose y, což představuje hodnotu závislé proměnné v případě, že nezávislá proměnná nabývá nulové hodnoty.

Důležitou součástí analýzy je také hodnota R^2 , koeficient determinace, který vyjadřuje míru, do jaké model vysvětluje rozptyl dat. Tento koeficient ukazuje efektivitu modelu při předpovídání výsledků.



Obrázek 5: Lineární regrese rozpočtu a realizací (zdroj: vlastní)

Tento bodový diagram s lineární regresní přímkou znázorňuje vztah mezi rozpočtem projektu a počtem realizovaných prací. Jeho cílem je analyzovat, jak se počet prací mění v závislosti na výši rozpočtu, a pomocí regresního modelu předpovědět budoucí hodnoty.

Graf obsahuje osu X označenou jako „Rozpočet (Kč)“, která představuje výši finančních prostředků vynaložených na projekty. Hodnoty na této ose rostou, čímž odrážejí různé investiční úrovně. Osa Y je pojmenovaná jako „Počet realizovaných prací (ks)“ a ukazuje, kolik prací bylo za daný rozpočet dokončeno.

Každý bod v grafu představuje jedno konkrétní pozorování – jedná se o dvojici hodnot rozpočtu a odpovídajícího počtu realizovaných prací. Rozložení bodů naznačuje rozptyl dat, tedy jak moc se jednotlivé hodnoty od sebe liší.

V grafu je vykreslena červená regresní přímka, která ukazuje lineární vztah mezi rozpočtem a počtem realizovaných prací. Její rovnice je:

$$y = 3E - 05x + 3,5655$$

Tato rovnice umožňuje predikci počtu realizovaných prací na základě zadaného rozpočtu:

- Koeficient $3E - 05$ (sklon přímky) určuje, že každé zvýšení rozpočtu o 1 Kč vede k malému nárůstu počtu realizovaných prací.
- Průsečík přímky s osou Y (3,5655) představuje počet realizovaných prací při nulovém rozpočtu. I když tato hodnota nemá praktický význam, je součástí matematického modelu.

Důležitým ukazatelem přesnosti tohoto modelu je koeficient determinace R^2 , který má v tomto případě hodnotu:

$$R^2 = 0,5593$$

Hodnota R^2 vyjadřuje, jak dobře regresní model odpovídá reálným datům.

- Pokud by $R^2 = 1$, znamenalo by to dokonalou predikci – model by přesně odpovídal všem datům.
- Pokud by $R^2 = 0$, znamenalo by to nulovou závislost – mezi rozpočtem a počtem prací by nebyl žádný vztah.
- Hodnota 0,5593 tedy znamená, že 56 % variability počtu realizovaných prací lze vysvětlit rozpočtem. Zbýlých 44 % je ovlivněno dalšími faktory, například složitostí projektů, efektivitou realizace nebo jinými nepredikovatelnými aspekty.

Graf ukazuje, že mezi rozpočtem projektu a počtem realizovaných prací existuje středně silná pozitivní korelace. To znamená, že obecně vyšší rozpočet vede k vyššímu počtu realizovaných prací, i když vztah není dokonalý. V reálném světě mohou do procesu vstupovat další vlivy, které tento model nezachycuje.

Regresní přímka pomáhá odhadnout, jaký počet prací lze očekávat při určitém rozpočtu. Pokud bychom například uvažovali projekt s rozpočtem 400 000 Kč, můžeme použít regresní rovnici:

$$y = 3E - 05 \times 400000 + 3,5655 = 15,5655$$

Což znamená, že při této investici lze očekávat přibližně 15 realizovaných prací.

Pro potvrzení funkčnosti lineární regresní rovnice ověříme její výpočty na konkrétních hodnotách rozpočtu. Regresní rovnice, která popisuje vztah mezi rozpočtem a počtem realizovaných prací, má tvar:

$$y = 3E - 05 \times x + 3,5655$$

kde:

- x je rozpočet v korunách (Kč),
- y je predikovaný počet realizovaných prací.

Příklad 1: Rozpočet 350 000 Kč. Dosazením hodnoty 350 000 Kč do rovnice získáme:

$$y = 3E - 05 \times 350000 + 3,5655$$

Nejprve vypočítáme první člen:

$$3E - 05 \times 350000 = 10,5$$

Poté přičteme konstantu:

$$10,5 + 3,5655 = 14,0655$$

Výsledkem je přibližně 14 realizovaných prací při rozpočtu 350 000 Kč.

Příklad 2: Rozpočet 210 000 Kč. Podobně ověříme výpočet pro 210 000 Kč:

$$y = 3E - 05 \times 210000 + 3,56556,3 + 3,5655 = 9,8655$$

Model tedy odhaduje přibližně 10 realizovaných prací při rozpočtu 210 000 Kč.

Výpočty potvrzují funkčnost regresní rovnice, která umožňuje predikci počtu realizovaných prací na základě rozpočtu projektu. I když hodnoty nejsou vždy dokonale přesné, poskytují užitečný nástroj pro odhad efektivitu investic. Pokud by bylo potřeba zpřesnit predikce, bylo by vhodné použít pokročilejší analytické metody, například nelineární regresi nebo modely strojového učení.

4.1.4.1 *Možné využití lineární regresní analýzy*

Na základě historických dat je možné využít regresní model k predikci budoucích projektů. Tento přístup umožňuje odhadnout, jaký rozpočet bude nutný k dosažení určitého počtu realizovaných prací. Pomocí matematické analýzy lze předpovědět očekávané výsledky, což pomáhá při plánování a rozpočtování budoucích investic.

Dále lze model využít k hodnocení efektivity investic, tedy k analýze, jak efektivně jsou finanční prostředky využívány. Pokud například vyšší rozpočty vedou k úměrnému nárůstu počtu realizovaných prací, znamená to, že investice jsou efektivní. Naopak pokud vztah mezi rozpočtem a počtem prací není tak výrazný, je možné, že existují faktory ovlivňující efektivitu, které nejsou zahrnuty v modelu.

Nakonec lze tento model použít k porovnání různých strategií financování projektů. Je možné ověřit, zda lineární přístup k rozpočtování odpovídá reálným výsledkům, nebo zda je nutné uvažovat o jiných analytických metodách, například nelineární regresi. Některé projekty mohou mít složitější vztahy mezi investicí a výstupem, které vyžadují pokročilejší statistické metody pro přesnější analýzu a predikci výsledků.

Tento graf poskytuje užitečnou předpověď o vztahu mezi rozpočtem a počtem realizovaných prací. I když regresní model není dokonale přesný, jeho hodnota $R^2 = 0,5593$ ukazuje, že rozpočet hraje významnou roli při určování počtu realizovaných prací. Výsledky mohou pomoci při plánování investic, optimalizaci rozpočtu a efektivnějším řízení projektů.

4.1.4.2 *Omezení lineární regrese*

Lineární regrese při predikci počtu realizovaných prací na základě rozpočtu má několik omezení. Především předpokládá přímý lineární vztah mezi proměnnými, což v realitě nemusí vždy platit. Vyšší rozpočty mohou být využity na různé aspekty projektu, například na kvalitu místo kvantity, což ovlivňuje výsledky.

Model pracuje pouze se dvěma proměnnými – rozpočtem a počtem prací, zatímco reálné projekty ovlivňují i další faktory, jako typ stavby, zkušenosti pracovníků nebo sezónní vlivy. To může vést k nepřesnostem v predikci, zejména u extrémních hodnot rozpočtu, které nebyly dostatečně reprezentovány v datech.

Regresní analýza může být také ovlivněna šumem v datech a nelinearitou vztahu, kdy růst investic nemusí vždy vést k odpovídajícímu zvýšení počtu realizovaných prací. Pro

přesnější predikce by bylo vhodné použít pokročilejší metody strojového učení, například nelineární regresní modely nebo neuronové sítě, které lépe zachytí komplexní vztahy mezi proměnnými.

4.1.5 Analýza časové řady pomocí ARIMA modelu

V této části práce použijeme metodu analýzy časových řad, která nám umožní detailně sledovat vývoj poptávky po lepicí a stěrkové hmotě v průběhu roku 2024. Hlavním cílem této analýzy je identifikovat trend prodeje, možné sezónní výkyvy a na základě historických dat vytvořit predikci budoucí poptávky.

Pomocí časové řady můžeme určit, zda poptávka v průběhu roku vykazuje růst, pokles nebo stabilitu, a zda existují pravidelné změny v prodeji v závislosti na ročním období. Na základě těchto informací dokážeme optimalizovat skladové zásoby a upravit strategii nákupu materiálu pro následující období. Výsledky této analýzy nám poskytnou konkrétní podklady pro rozhodování a umožní efektivnější plánování zásob i obchodních aktivit společnosti.

4.1.5.1 Příprava datasetu

Pro tuto analýzu jsme sestavili časovou řadu, která zachycuje měsíční prodeje lepicí a stěrkové hmoty za rok 2024. Tabulka zahrnuje nejen objem prodaného materiálu v kilogramech, ale také jednotkovou cenu za 1 kg a celkový zisk daném měsíci. Díky těmto údajům dokážeme identifikovat trendy v poptávce, sezónní výkyvy a vliv cenových změn na celkový výsledek.

Data byla uložena do tabulkové struktury pomocí knihovny pandas a následně převedena na časovou řadu pomocí indexování podle data.

```
import pandas as pd

# Vytvoření datasetu
data = {
    "Měsíc": ["2024-01", "2024-02", "2024-03", "2024-04", "2024-05", "2024-06",
              "2024-07", "2024-08", "2024-09", "2024-10", "2024-11", "2024-12"],
    "Prodeje": [2300, 2900, 3200, 3600, 4000, 4500, 3800, 4000, 3500, 3000, 2600, 2300]
}

# Převod na DataFrame
df = pd.DataFrame(data)

# Převedení na časovou řadu
df["Měsíc"] = pd.to_datetime(df["Měsíc"])
df.set_index("Měsíc", inplace=True)

print(df.head())
```

Měsíc	Prodeje
2024-01-01	2300
2024-02-01	2900
2024-03-01	3200
2024-04-01	3600
2024-05-01	4000

Obrázek 6: Příprava datasetu v pandas (zdroj: vlastní)

Níže uvedená tabulka poté dále poskytuje přehled o vývoji prodejů v jednotlivých měsících roku 2024:

Měsíc	Prodané množství (kg)	Cena za 1 kg (Kč)	Celkový zisk (Kč)
Leden	2 300	25	57 500
Únor	2 900	24	69 600
Březen	3 200	23	73 600
Duben	3 600	22	79 200
Květen	4 000	21	84 000
Červen	4 500	20	90 000
Červenec	3 800	21	79 800
Srpen	4 000	22	88 000
Září	3 500	23	80 500
Říjen	3 000	24	72 000
Listopad	2 600	25	65 000
Prosinec	2 300	26	59 800


Tabulka 3: Přehled měsíčních prodejů lepicí a šterkové hmoty v roce 2024 (zdroj: vlastní)

Z tabulky je patrné, že nejvyšší prodeje byly zaznamenány v letních měsících květen a červen, kdy poptávka po lepicí a stěrkové hmotě dosáhla vrcholu. Naopak nejnižší prodeje byly v zimních měsících leden a prosinec, což naznačuje možný sezónní vliv. Je vidět, že cena materiálu se v průběhu roku mění. Nejnižší cena byla v červnu (20 Kč/kg), což přispělo k vyšším prodejům, zatímco nejvyšší cena byla v prosinci (26 Kč/kg), kdy byl objem prodeje nejnižší. Tato skutečnost naznačuje možnou korelaci mezi cenou a poptávkou.

Celkový zisk kopíruje trend poptávky – nejvyšší byl v červnu (90 000 Kč) a nejnižší v lednu a prosinci. Tyto informace jsou klíčové pro optimalizaci skladových zásob a cenové strategie v následujícím roce.

4.1.5.2 Vizualizace trendů

Na základě tabulky, která zachycuje měsíční prodeje lepicí a stěrkové hmoty v roce 2024, jsme vytvořili graf znázorňující trend poptávky v průběhu roku. Tento graf nám pomůže lépe vizualizovat dynamiku prodeje, identifikovat sezónní výkyvy a umožní přesnější interpretaci dat.



Obrázek 7: Měsíční poptávka po lepicí a stěrkové hmotě v roce 2024 (zdroj: vlastní)

Graf jasně ukazuje, že poptávka po lepicí a stěrkové hmotě byla nejnižší v zimních měsících, konkrétně v lednu a prosinci, kdy bylo prodáno 2 300 kg. Naopak nejvyšší prodeje

byly dosaženy v červnu, kdy odběr materiálu dosáhl 4 500 kg, což naznačuje, že v tomto období dochází ke zvýšené stavební aktivitě.

Počínaje lednem vidíme postupný růst poptávky, která se stabilně zvyšuje až do června, kdy dosahuje svého vrcholu. Následně dochází ke krátkodobému poklesu v červenci a srpnu, kdy se prodeje pohybují kolem 4 000 kg, což může souviset s letními dovolenými a sníženou aktivitou stavebních projektů. Od září začíná další mírný pokles, který kulminuje v prosinci. Tento sezónní vývoj je klíčový pro efektivní řízení zásob a plánování nákupů. Pokud víme, že nejvyšší poptávka nastává v květnu a červnu, můžeme na toto období připravit dostatečné skladové zásoby. Naopak v zimních měsících lze upravit objednávky tak, aby odpovídaly nižšímu odběru materiálu.

Dalším faktorem ovlivňujícím poptávku je cena materiálu, která se v průběhu roku mění. Nejnižší cena byla zaznamenána v červnu, kdy byly prodeje na svém maximu, zatímco nejvyšší cena v prosinci korespondovala s obdobím nejnižší poptávky. To naznačuje, že trh může být citlivý na cenové změny, což je důležitá informace pro strategické plánování cenové politiky.

Celkově graf potvrzuje výrazný sezónní charakter poptávky po lepicí a stěrkové hmotě, kdy prodeje v teplejších měsících rostou, zatímco zimní období vykazuje nižší hodnoty. Tyto poznatky lze využít k optimalizaci skladových zásob a k efektivnějšímu řízení obchodní strategie.

V pandas jsme si vytvořili kódovou buňku pro tento graf, abychom poté mohli na základě tohoto kódu vytvořit test stacionarity Dickey-Fuller testem.

```
import matplotlib.pyplot as plt

plt.figure(figsize=(10, 5))
plt.plot(df["Prodeje"], marker="o", linestyle="--", color="b")
plt.title("Vývoj prodejů lepicí a stěrkové hmoty (2024)")
plt.xlabel("Měsíc")
plt.ylabel("Prodané množství (kg)")
plt.show()
```

Obrázek 8: Graf vizualizace trendů v pandas (zdroj: vlastní)

Pomocí vizualizace bylo možné odhalit případné významné sezónní cykly nebo nestandardní výkyvy, což umožňuje přesnější nastavení parametrů ARIMA modelu.

4.1.5.3 Testování stacionarity Dickey-Fuller testem

ARIMA model vyžaduje stacionární časovou řadu, což znamená, že průměr a rozptyl dat zůstávají konstantní v čase. Ke zjištění, zda jsou data stacionární, byl použit Dickey-Fuller test, který statisticky ověřuje přítomnost trendu v časové řadě.

```
from statsmodels.tsa.stattools import adfuller

result = adfuller(df["Prodeje"])
print("P-hodnota:", result[1])
```

P-hodnota: 0.4944629463289777

Obrázek 9: Testování stacionarity Dickey-Fuller testem v pandas (zdroj: vlastní)

Pokud p-hodnota vyšla vyšší než 0.05, znamená to, že data nejsou stacionární a je nutné provést diferenciaci, což je metoda odstranění trendu odečtením hodnoty předchozího období od aktuální hodnoty:

```
df["Prodeje_diff"] = df["Prodeje"].diff().dropna()
```

Obrázek 10: Diferenciace v případě p-hodnoty vyšší než 0,05 v pandas (zdroj: vlastní)

4.1.5.4 Aplikace ARIMA modelu

Po provedené diferenciaci byla nastavena konfigurace ARIMA modelu, který byl následně aplikován na časovou řadu. Hodnoty parametrů (p, d, q) byly zvoleny na základě analýzy autokorelační funkce (ACF) a parciální autokorelační funkce (PACF).

```
from statsmodels.tsa.arima.model import ARIMA

# Nastavení modelu
model = ARIMA(df["Prodeje"], order=(2,1,2)) # p=2, d=1, q=2
```

Obrázek 11: Aplikace ARIMA modelu v pandas (zdroj: vlastní)

4.1.5.5 Predikce pro rok 2025

Na základě natrénovaného modelu byla provedena predikce budoucího vývoje poptávky na následujících 12 měsících. Výsledné hodnoty umožňují efektivnější plánování zásob a obchodní strategie.

```
forecast = model_fit.predict(start=len(df), end=len(df)+11, dynamic=True)  
print(forecast)
```

2025-01-01	2067.451249
2025-02-01	1960.877571
2025-03-01	1917.148479
2025-04-01	1901.664663
2025-05-01	1897.503192
2025-06-01	1897.207241
2025-07-01	1897.860825
2025-08-01	1898.508632
2025-09-01	1898.941968
2025-10-01	1899.185412
2025-11-01	1899.306876
2025-12-01	1899.361476

Obrázek 12: Predikce pro rok 2025 v pandas (zdroj: vlastní)

Predikce poskytuje data o očekávaných prodejkách, která lze využít pro obchodní rozhodování a řízení zásob podle sezónních výkyvů poptávky.

4.1.5.6 Shrnutí metodologie

Tento postup zahrnoval všechny kroky nutné pro aplikaci ARIMA modelu na historická data prodejů lepicí a stěrkové hmoty. Díky analýze stacionarity, diferenciaci a vizualizaci bylo možné provést přesnější predikci pro další období. Výsledky poskytují cenné podklady pro efektivní skladovou strategii a plánování zásob na základě očekávaného vývoje poptávky.

4.2 Výsledky a jejich interpretace

4.2.1 Vyhodnocení výsledků Lineární regresní analýzy

Jedním z hlavních cílů této studie bylo provést lineární regresní analýzu, která měla za úkol zjistit vztah mezi investovaným rozpočtem a počtem realizovaných stavebních prací. Lineární regresní model poskytuje statistickou metodu pro odhad vztahu mezi dvěma proměnnými, přičemž jeho aplikace ve stavebnictví umožnila přesněji predikovat rozsah realizovaných činností při různých úrovních investice.

Analýza ukázala pozitivní korelaci mezi výší investovaných prostředků a počtem dokončených stavebních prací, což naznačuje, že vyšší finanční investice obecně vedou k většímu objemu realizovaných činností. Regresní model byl reprezentován následující rovnicí:

$$y = 3E - 05x + 3,5655$$

Klíčovou metrikou pro vyhodnocení přesnosti modelu byla hodnota koeficientu determinace (R^2), která dosáhla 0,5593. To znamená, že 56 % variability v počtu dokončených činností lze vysvětlit změnami v investovaných prostředcích, zatímco zbylých 44 % je ovlivněno dalšími faktory, jako jsou efektivita projektového řízení, sezónní vlivy, dostupnost pracovní síly či dodací lhůty materiálu.

Výsledky analýzy přinášejí cenné poznatky pro optimalizaci logistických procesů ve stavebnictví. Strategické plánování rozpočtu hraje klíčovou roli v řízení investic, protože umožňuje efektivnější alokaci finančních prostředků pro různé fáze stavebních projektů. Díky tomu mohou podniky lépe nastavit své kapacity, minimalizovat náklady a zajistit plynulost stavebních operací.

Dalším důležitým aspektem je predikce rozsahu prací, která se opírá o výsledky regresní analýzy. Díky statistickým modelům lze s vysokou mírou pravděpodobnosti odhadnout, kolik stavebních činností bude realizováno při dané úrovni investice. Tento přístup značně usnadňuje rozhodování o financování projektů, protože umožňuje podnikům lépe plánovat využití zdrojů a eliminovat riziko neefektivního rozložení rozpočtu.

Součástí těchto optimalizačních procesů je také řízení pracovních zdrojů, kde se analýza ukázala jako klíčový nástroj pro správné přizpůsobení nasazení pracovní síly podle očekávaného objemu investic. Podniky tak mohou lépe organizovat své stavební operace, zajistit jejich plynulost a optimalizovat pracovní kapacity podle aktuálních potřeb.

Nakonec je zásadní přehled o efektivitě investic, který poskytuje jasnou představu o návratnosti investovaných prostředků. Regresní model umožňuje sledovat, jak různé typy projektů ovlivňují výsledné náklady, a pomáhá podnikům při rozhodování o budoucím rozpočtovém plánování na základě podložených dat. Díky těmto informacím mohou firmy nejen efektivněji řídit své finanční toky, ale také optimalizovat procesy tak, aby dosahovaly maximálního výkonu s minimálními náklady.

4.2.2 Vyhodnocení výsledků predikce pomocí ARIMA modelu

Druhou významnou částí analýzy bylo vytvoření predikčního modelu pomocí ARIMA, který umožnil analyzovat časovou řadu poptávky po lepicí a stěrkové hmotě v průběhu roku 2024 a vytvořit přesnou prognózu pro rok 2025.

Analýza časových řad ukázala výrazné sezónní výkyvy, přičemž nejvyšší prodeje byly zaznamenány v květnu a červnu, zatímco v zimních měsících (leden a prosinec) došlo k výraznému poklesu poptávky. Tento sezónní charakter poptávky naznačuje, že stavebnictví je silně ovlivněno klimatickými podmínkami a sezónními faktory, což je zásadní poznatek pro logistické plánování a řízení zásob.

Další významný faktor, který ovlivnil dynamiku poptávky, byla cena materiálu – nejnížší cena byla zaznamenána v červnu, kdy byly prodeje na svém maximu, zatímco nejvyšší cena v prosinci vedla k poklesu prodejů. To naznačuje cenovou elasticitu materiálu, což lze využít při optimalizaci cenových strategií.

Výsledky analýzy poskytují důležité poznatky pro optimalizaci logistických procesů, zejména v oblasti skladového hospodářství a řízení dodavatelského řetězce. Díky sezónním predikcím lze přesně upravit zásobování tak, aby odpovídalo očekávané poptávce, což vede ke snížení skladovacích nákladů a minimalizaci rizika přebytků nebo nedostatků materiálu. Tento přístup umožňuje firmám efektivně plánovat nákupní a skladovací strategie, přičemž zajišťuje optimální využití skladových kapacit.

Dalším klíčovým faktorem je cenová optimalizace, která se ukázala jako významný nástroj pro řízení poptávky. ARIMA model potvrdil, že správné nastavení cenové politiky může pozitivně ovlivnit objem prodeje. Nižší ceny v obdobích vyšší poptávky mohou podpořit ještě vyšší objemy prodejů, zatímco úprava cen v době nižší aktivity pomáhá stabilizovat celkové výnosy. Tímto způsobem se firmy mohou lépe adaptovat na tržní podmínky a zároveň zajistit udržení konkurenceschopnosti na trhu.

Predikce budoucích výkyvů v poptávce představuje zásadní výhodu pro plánování objednávek. Analýza časové řady umožňuje předvídat budoucí trendy a tím pomoci firmám efektivněji optimalizovat nákupní strategie. Díky tomu mohou podniky přesněji řídit objem objednávek, vyhnout se nečekaným výpadkům v dodávkách materiálu a zajistit plynulost zásobování v klíčových obdobích.

Výsledky ARIMA modelu navíc přispívají k zlepšení dodavatelského řetězce. Možnost synchronizace dodávek s očekávanou poptávkou poskytuje firmám výraznou výhodu při

řízení logistických operací. Lepší koordinace mezi dodavateli a odběrateli umožňuje minimalizovat skladové zásoby, snižovat provozní náklady a zároveň zajistit rychlejší reakce na tržní změny.

4.3 Diskuse nad výsledky

Použité metody přinesly řadu výhod, které výrazně přispěly k efektivnějšímu řízení logistických procesů a plánování investic. Regresní analýza se ukázala jako užitečný nástroj pro sestavení přehledného prediktivního modelu, který umožňuje odhadnout počet realizovaných stavebních prací při různých úrovních investic. Díky tomu bylo možné optimalizovat rozpočtové plánování, což firmám poskytuje lepší kontrolu nad alokací finančních prostředků a umožňuje jim lépe řídit využití zdrojů.

Další významnou metodou byla analýza časových řad pomocí ARIMA modelu, která umožnila vytvořit přesnější předpověď poptávky. To má zásadní dopad na řízení skladových zásob, protože firmy mohou na základě této predikce lépe plánovat své objednávky a minimalizovat náklady na nadbytečné skladování. Snižování provozních nákladů a optimalizace skladových procesů umožňují efektivnější provoz a vyšší konkurenceschopnost na trhu.

Obě metody poskytují robustní analytický základ, který pomáhá podnikům při strategickém rozhodování v oblasti financování, zásobování i řízení projektů. Prediktivní modely umožňují podnikům nejen efektivně plánovat své investice, ale také reagovat na vývoj trhu s vyšší přesností, čímž zlepšují efektivitu svého rozhodovacího procesu.

Nicméně i přes tyto výhody je nutné brát v úvahu omezení použitých metod. Regresní analýza pracuje pouze s finančními údaji a nezahrnuje další proměnné, jako jsou sezónní výkyvy, kvalita pracovní síly nebo makroekonomické podmínky, což může ovlivnit přesnost predikcí. Tyto faktory mohou významně ovlivnit výsledky, a proto je důležité doplnit analýzu o širší spektrum dat pro dosažení vyšší spolehlivosti modelu.

ARIMA model se zase opírá o historická data, což znamená, že je citlivý na neočekávané tržní změny, například ekonomické krize, legislativní úpravy nebo změny v dodavatelských řetězcích. To může vést k tomu, že predikce nebude plně reflektovat aktuální dynamiku trhu. (Bektemyssova et al., 2022, s.)

Pro zvýšení přesnosti predikce by bylo vhodné rozšířit analýzu o makroekonomické faktory, konkurenční analýzy a dynamiku trhu s materiály, které by umožnily lépe odhadnout budoucí vývoj v oblasti stavebnictví a logistiky. Spojením těchto přístupů s moderními metodami, jako je strojové učení, by bylo možné vytvořit komplexnější a přesnější prediktivní modely, které by zajistily ještě efektivnější rozhodování.

Celkově vzato, regresní analýza a ARIMA model společně přinesly zásadní přínosy pro plánování a řízení logistických procesů, ale zároveň existuje prostor pro jejich další vylepšení. Využití pokročilejších analytických metod a rozšíření datového spektra by mohlo vést k vytvoření ještě sofistikovanějších predikčních modelů, které by firmám umožnily ještě lépe optimalizovat své procesy a dosahovat maximální efektivity.

4.4 Polostrukturované rozhovory

Jakým způsobem vaše společnost využívá prediktivní analýzu v logistice?

Vedoucí skladu: „*Naše společnost se snaží využívat prediktivní analýzu jako klíčový nástroj pro optimalizaci logistických operací. Na základě historických dat a analytických modelů předpovídáme budoucí poptávku, což nám umožňuje lépe řídit skladové zásoby a plánovat dodávky. Například pomocí regresní analýzy sledujeme, jak investice do konkrétních logistických procesů ovlivňují efektivitu dodavatelského řetězce. S využitím ARIMA modelů analyzujeme sezónní výkyvy v prodeji, což nám umožňuje včas připravit zásoby na období zvýšené poptávky a zároveň minimalizovat nadměrné skladování v klidnějších obdobích roku. Dále propojujeme prediktivní analýzu s naším ERP systémem, kde automaticky nastavujeme objednávky na základě očekávané potřeby zásob, čímž eliminujeme riziko neefektivního skladování a přebytných nákladů.*”

Jaký vidíte největší přínos prediktivní analýzy pro budoucnost firmy?

Vedoucí skladu: „*Prediktivní analýza nám umožňuje nejen efektivnější řízení skladových zásob, ale také lepší alokaci zdrojů a celkové zlepšení provozní efektivity. Největším přínosem je schopnost přesně odhadovat poptávku, což znamená, že se můžeme připravit na sezónní výkyvy a zajistit dostatek materiálu bez zbytečných přebytků. Díky predikci jsme schopni snižovat provozní náklady tím, že optimalizujeme zásoby a eliminujeme zbytečné objednávky, které by vedly k nadměrnému skladování. Také vidíme*

velkou přidanou hodnotu v řízení přepravních procesů, kdy na základě historických dat předpovídáme optimální trasy pro dopravu zásilek a minimalizujeme zpoždění. To má přímý vliv na kvalitu služeb, protože zákazníci dostávají objednávky včas a v optimálním množství."

Jaké konkrétní kroky podnikáte pro implementaci prediktivních modelů?

Vedoucí skladu: *„V první řadě jsme integrovali prediktivní analytické nástroje do našeho ERP systému, který nám umožňuje sledovat a analyzovat historická data pro přesnější predikci budoucí poptávky. Dále jsme navázali užší spolupráci s dodavateli, aby naše objednávky reflektovaly vývoj poptávky v reálném čase. Zavádíme automatizaci logistických procesů, kdy využíváme prediktivní analýzu k dynamickému nastavování skladových zásob a transportních kapacit podle očekávané potřeby. Kromě toho průběžně aktualizujeme naše analytické modely a testujeme jejich přesnost, aby reflektovaly aktuální změny na trhu, jako jsou změny cen materiálu nebo vývoj poptávky ze strany zákazníků."*

V jakých oblastech vaší logistiky vidíte největší potenciál prediktivní analýzy?

Vedoucí skladu: *„Největší potenciál vidíme v optimalizaci skladového hospodářství, řízení přepravních tras a dynamickém nastavení objednávek. V oblasti skladování můžeme pomocí prediktivní analýzy přesně odhadnout optimální množství zásob a tím minimalizovat náklady na skladování. Pokud jde o dopravu, prediktivní modely nám umožňují plánovat nejefektivnější trasy dodávek, což vede k úspoře času a financí. Dále je obrovským přínosem dynamická optimalizace objednávek – například pokud analýza ukáže, že v daném měsíci bude poptávka po určitém materiálu výrazně vyšší, naše objednávkový systém automaticky nastaví vyšší zásoby, čímž předejdeme případnému nedostatku."*

5 NÁVRHOVÁ ČÁST

5.1 Doporučení a návrhy na zlepšení

5.1.1 Optimalizace skladových zásob

Jedním z nejzásadnějších faktorů ovlivňujících efektivitu logistických operací je správné řízení skladových zásob. Výsledky ARIMA analýzy ukázaly, že poptávka po stavebním materiálu vykazuje výrazné sezónní výkyvy, což znamená, že nedostatečná predikce těchto trendů může vést k nadměrnému skladování nebo nedostatku zásob v klíčových obdobích. Aby bylo možné efektivně řídit zásoby a snížit náklady, je nezbytné implementovat prediktivní řízení skladových zásob, které umožní dynamické přizpůsobení skladových kapacit podle očekávaných změn v poptávce.

Prvním krokem k efektivní optimalizaci je integrace ARIMA modelu do řízení zásob, což umožní automatizované doplňování zásob podle predikovaných výkyvů poptávky. Systém bude využívat historická data o prodejkách a cenových trendech k odhadu, kdy nastane zvýšená potřeba materiálu, čímž se zabrání náhlým výpadkům skladových zásob. Dalším krokem je stanovení minimálních a maximálních skladových úrovní, což zajistí, že firma bude mít optimální množství zásob v každém období – v klíčových měsících s vysokou poptávkou bude sklad připraven na vyšší objem objednávek, zatímco v méně aktivních obdobích bude docházet k přirozené redukci zásob bez zbytečných skladovacích nákladů.

Pro maximální efektivitu je nutné propojit prediktivní model s ERP systémem firmy, což zajistí automatizaci objednávek a propojení predikcí s interními firemními daty. Pokud se poptávka v určitých obdobích výrazně zvýší, systém bude schopen včas upozornit na potřebu doplnění zásob, což zajistí nepřetržitou dostupnost materiálu. V neposlední řadě je vhodné zavést varovný systém, který upozorní na riziko přebytku nebo nedostatku zásob. Tento přístup umožní flexibilní řízení skladové kapacity, což povede k lepšímu plánování objednávek a eliminaci skladových přebytků.

5.1.2 Strategické plánování investic

Regresní analýza ukázala, že mezi investovaným rozpočtem a počtem realizovaných prací existuje pozitivní korelace, což potvrzuje, že správná alokace finančních prostředků

může výrazně ovlivnit rozsah stavebních projektů a jejich efektivitu. Aby bylo možné tyto poznatky využít pro strategické plánování investic, je nezbytné vytvořit dynamický rozpočtový model, který umožní přesnější předpověď potřebných investic na základě historických dat.

Tento model bude pracovat s reálnými daty o nákladech na jednotlivé projekty, cenách materiálů, dostupnosti pracovní síly a sezónních trendech, což umožní lepší predikci rozpočtových potřeb. Významným krokem je predikce návratnosti investic, což znamená, že podnik může přesněji odhadnout výnosnost stavebních projektů při různých investičních úrovních. Díky těmto predikcím je možné minimalizovat riziko nadměrných investic do neefektivních projektů, a naopak maximalizovat výnosnost dobře alokovaných prostředků.

Důležitým aspektem je také flexibilní alokace zdrojů – díky propojení finančních údajů s prediktivní analýzou lze předvídat potřebu pracovní síly, materiálu a vybavení, což umožní optimalizaci výrobních a realizačních kapacit. Tento přístup povede k nižším provozním nákladům a vyšší efektivitě projektů, protože podnik nebude alokovat zbytečné finanční prostředky do zdrojů, které nejsou aktuálně potřebné. Součástí efektivního plánování investic je také zlepšení řízení kapitálu, kdy dynamické plánování rozpočtu umožní rychlejší reakce na změny v investičních potřebách, což zajistí stabilnější finanční strategii firmy.

5.1.3 Cenová optimalizace

Výsledky ARIMA modelu ukázaly, že poptávka po stavebním materiálu je citlivá na cenové změny, což naznačuje, že správné řízení cenové politiky může být účinným nástrojem pro řízení prodejů. Vzhledem k sezónním výkyvům v poptávce je nezbytné zavést dynamickou cenovou strategii, která umožní pružnou úpravu cen podle aktuálních tržních podmínek.

Jedním z hlavních kroků je zavedení sezónního cenového modelu, který umožní automatickou úpravu cen na základě očekávané poptávky. Pokud je například poptávka vysoká v letních měsících, firma může strategicky optimalizovat ceny tak, aby maximalizovala zisky. Součástí cenové optimalizace je také analýza konkurence, která umožní dynamické řízení cen na základě konkurenčního prostředí.

Dalším přístupem je optimalizace cenových nabídek pro velké odběratele. Pokud podnik dokáže předpovědět vyšší odběr materiálu v určitém období, může nabídnout

výhodnější podmínky pro velké zákazníky, což povede k vyšším objemům prodeje a udržení dlouhodobých obchodních vztahů. Pro zajištění maximální efektivity je vhodné testovat cenové strategie pomocí simulací, kde se na základě historických dat ověřují různé cenové scénáře. Tento přístup umožní vybrat neoptimálnější cenovou strategii, která zajistí maximalizaci výnosů.

5.1.4 Logistická synchronizace

Analýza ukázala, že dodavatelský řetězec může být v klíčových obdobích zatížen vyšší poptávkou, což vede ke zpožděním dodávek a vyšším nákladům na přepravu. Aby se eliminovaly tyto negativní jevy, je nezbytné automatizovat řízení dodávek a optimalizovat logistické procesy.

Jedním z hlavních kroků je integrace prediktivního modelu do řízení objednávek, což umožní automatizované generování doporučení pro objednávky materiálu podle očekávané poptávky. Součástí logistické optimalizace je plánování tras dodávek, které bude využívat historická data o přepravě a dodacích lhůtách k efektivnějšímu řízení přepravy.

Důležitým opatřením je automatická koordinace s dodavateli, což zajistí lepší plánování výroby a synchronizaci skladových zásob. Díky prediktivním modelům budou dodavatelé informováni o očekávaném zatížení skladu, což povede k nižším výpadkům v dodávkách a lepší organizaci zásob. Celkově tato opatření povedou ke snížení provozních nákladů, rychlejší dodávkám materiálu a efektivnějšímu řízení logistických operací.

5.2 Konkrétní kroky pro implementaci doporučených změn

Aby bylo možné efektivně aplikovat návrhy na zlepšení, je nutné podrobně rozpracovat jednotlivé kroky, které zajistí úspěšné zavedení změn do praxe. Klíčovým faktorem je správná integrace prediktivních metod do existujících systémů společnosti, což povede ke zvýšení efektivity v oblasti řízení skladových zásob, plánování investic, cenové politiky a logistických procesů.

5.2.1 Zavedení systému prediktivního řízení skladových zásob

Správa skladových zásob je klíčovým prvkem každého logistického procesu, a právě ARIMA model poskytuje nástroje pro přesnější predikci poptávky, což umožní optimalizovat skladové kapacity. Integrace tohoto modelu do firemního ERP systému zajistí, že objednávky budou automaticky generovány na základě predikovaných výkyvů poptávky. To znamená, že systém bude pracovat s historickými daty a nastaví objednávky materiálu v momentě, kdy je jeho doplnění potřeba.

Aby byla zajištěna přesnost predikcí, je nezbytné vytvořit historickou databázi prodeje, která bude pravidelně aktualizována a propojena s ostatními interními daty. Databáze by měla obsahovat detailní záznamy o sezónních trendech, objemu prodeje v jednotlivých měsících a cenových změnách. Díky tomu bude ARIMA model vždy pracovat s relevantními a aktuálními informacemi, což povede k přesnějším výsledkům.

Další důležitý krok představuje implementace varovného systému, který bude automaticky upozorňovat na nízkou úroveň skladových zásob v klíčových obdobích. Tento systém bude integrovaný do podnikových procesů a zajistí, že skladové zásoby budou vždy odpovídat reálné poptávce, čímž se minimalizuje riziko nadbytečného skladování nebo naopak nedostatku materiálu.

5.2.2 Optimalizace rozpočtového plánování

Efektivní finanční řízení je zásadní pro správnou alokaci prostředků do stavebních projektů. Regresní analýza ukázala, že vztah mezi rozpočtem a počtem realizovaných prací lze matematicky modelovat, což znamená, že investice lze předvídat a optimalizovat.

Prvním krokem je vytvoření matematického modelu, který na základě historických dat identifikuje nejefektivnější úrovně investic potřebné pro realizaci konkrétních stavebních činností. Model bude využívat analýzu předchozích projektů, přičemž zohlední různé finanční parametry, jako jsou náklady na materiál, počet pracovníků nebo celková délka realizace zakázky.

Dalším krokem je integrace tohoto modelu do finančního plánování společnosti, což zajistí, že rozpočtové rozhodování bude data-driven a umožní podnikům určovat prioritní investiční oblasti. Systém bude nastaven tak, aby poskytoval automatická doporučení pro optimální rozdělení finančních prostředků podle očekávaného výkonu projektů.

Díky těmto krokům bude možné snížit riziko nadměrných investic, vyhnout se neefektivnímu financování projektů a zároveň zajistit jejich úspěšnou realizaci.

5.2.3 Zavedení sezónního cenového modelu

Cenová politika hraje klíčovou roli při ovlivňování poptávky, což potvrzují výsledky analýzy ARIMA modelu. Z tohoto důvodu je nezbytné zavést dynamický cenový model, který umožní pružnou úpravu cen v závislosti na sezónních výkyvech poptávky.

Prvním krokem je analýza konkurence a historických cenových trendů, která poskytne základ pro sestavení cenového algoritmu. Tento algoritmus bude analyzovat sezónní výkyvy prodejů, cenové strategie konkurence a další faktory ovlivňující tržní podmínky, což zajistí optimalizaci cenových rozhodnutí.

Další fází je testování modelu na menším vzorku materiálu před jeho plošnou implementací. Tento krok umožní ověřit, jak se dynamická cenová politika projeví na objemu prodejů a zda jsou predikce ARIMA modelu v souladu s reálnými daty. Pokud testování přinese očekávané výsledky, cenový algoritmus bude postupně zaveden do celkového cenového řízení společnosti, čímž se zajistí automatizované přizpůsobení cen podle tržní situace.

Díky těmto změnám budou firmy schopny lépe reagovat na sezónní výkyvy, přizpůsobit svou cenovou politiku tak, aby maximalizovaly zisk, a zároveň si udržely konkurenceschopnost na trhu.

5.2.4 Automatizovaná logistická synchronizace

Logistické procesy často čelí výzvám spojeným se sezónními změnami v dodávkách materiálu. Výsledky analýzy naznačují, že synchronizace dodávek pomocí prediktivních algoritmů může vést k výraznému snížení nákladů a vyšší efektivitě celého dodavatelského řetězce.

Prvním krokem je integrace prediktivních algoritmů do řízení objednávek, což umožní automatizované doporučení optimálních objednávek na základě očekávané poptávky. Tento systém bude pracovat s historickými daty a sezónními výkyvy, což zajistí, že objednávky budou přesně odpovídat potřebám firmy v daném období.

Dalším krokem je spolupráce s dodavateli na vytvoření flexibilního dodacího modelu, který umožní dynamické přizpůsobení kapacit přepravy v závislosti na změnách v poptávce. Firmy budou schopny minimalizovat náklady na dopravu, snížit počet zpožděných dodávek a zajistit plynulý tok materiálu.

Důležitým aspektem logistické synchronizace je prediktivní řízení skladových zásob v distribučních centrech, což pomůže efektivněji řídit zásoby a minimalizovat nadměrné skladování. Implementace prediktivních modelů do řízení skladů zajistí, že objem zásob bude přesně odpovídat očekávaným potřebám trhu, čímž se sníží provozní náklady.

Celkově tyto kroky povedou ke zlepšení koordinace mezi odběrateli a dodavateli, vyšší efektivitě řízení logistických operací a optimalizaci nákladů spojených s distribucí stavebního materiálu.

5.3 Odhad nákladů a přínosů navrhovaných změn

Aby bylo možné efektivně vyhodnotit, zda zavedení navrhovaných optimalizací přinese očekávané výsledky, je důležité podívat se na jejich finanční náročnost a přínosy pro podnik. Tabulka níže poskytuje přehled jednotlivých doporučení, včetně jejich očekávaných výhod.

Doporučení	Odhad přínosů
Prediktivní řízení zásob	Snížení skladovacích nákladů, optimalizace zásob
Optimalizace rozpočtového plánování	Efektivnější alokace investic, vyšší výkonnost projektů
Sezónní cenový model	Zvýšení prodeje v klíčových obdobích, udržení konkurenceschopnosti
Automatizace dodavatelského řetězce	Snížení nákladů na dopravu, lepší synchronizace dodávek

Tabulka 4: Odhady přínosu z jednotlivých doporučení (zdroj: vlastní)

Prediktivní řízení zásob pomůže lépe plánovat objednávky materiálu díky integraci ARIMA modelu do ERP systému. Důležitá je také pravidelná aktualizace historické databáze prodeje, která zajistí přesnost predikcí. K tomu se přidává varovný systém, který upozorní na nutnost doplnění zásob v sezónních obdobích, čímž se minimalizuje riziko nedostatků.

Optimalizace rozpočtového plánování umožní efektivnější využití investic díky matematickému modelu vycházejícímu z historických dat o nákladech projektů. Jeho integrace do finančního řízení společnosti pomůže lépe určovat investiční priority a zajistí stabilní rozpočtové plánování.

Sezónní cenový model zajistí flexibilní úpravu cen podle aktuální poptávky. K tomu poslouží analýza konkurence a tržních trendů, na jejichž základě se nastaví cenový algoritmus. Testování modelu na vybraném materiálu pomůže doladit cenovou strategii před plošným zavedením.

Automatizace dodavatelského řetězce optimalizuje objemy objednávek pomocí prediktivních algoritmů, čímž se snižují náklady na přepravu a minimalizují zpoždění dodávek. Spolupráce s dodavateli na flexibilním dodacím modelu umožní efektivnější synchronizaci zásob a zlepši koordinaci logistických procesů.

5.4 Možnosti dalšího výzkumu v oblasti prediktivní analýzy v logistice

Prediktivní analýza se ukázala jako užitečný nástroj pro řízení zásob a plánování investic, ale pořád existují způsoby, jak ji dále vylepšit. Jednou z možností je zahrnout ekonomické faktory do modelů, protože ceny energií nebo změny v legislativě mohou ovlivnit poptávku po stavebních materiálech. Pokud by se tyto faktory zapracovaly do predikcí, bylo by možné lépe přizpůsobit skladování i cenovou strategii.

Další zajímavou možností je analýza vlivu počasí na poptávku. Víme, že stavební sezóna ovlivňuje prodeje, ale kdybychom do modelu přidali meteorologická data, mohli bychom přesněji odhadnout období zvýšené stavební aktivity a přizpůsobit tomu zásoby.

Také by stálo za to podrobněji zkoumat cenovou elasticitu, tedy jak se poptávka mění podle ceny. Už teď víme, že nižší ceny zvyšují prodeje, ale bylo by fajn zjistit, které materiály jsou na změny cen nejcitlivější. To by pomohlo při nastavování sezónních slev a strategických cenových úprav.

Kombinací těchto přístupů by bylo možné ještě lépe plánovat zásoby, optimalizovat ceny a reagovat na změny na trhu, což by firmě pomohlo být efektivnější a konkurenceschopnější.

5.5 Navrhované směry pro rozšíření a prohloubení stávajících poznatků

Prediktivní analýza má velký potenciál, pokud se rozšíří o další faktory, které lépe reflektují reálné podmínky na trhu a umožní firmám dělat ještě přesnější rozhodnutí. Jednou z možností je rozšíření analýzy na více druhů stavebních materiálů. Dosud jsme se zaměřovali hlavně na lepicí a stěrkovou hmotu, ale stejné principy lze využít i u dalších materiálů, jako jsou betonové směsi, izolace nebo stavební dřevo. Pokud by prediktivní model zahrnoval širší škálu produktů, bylo by možné lépe plánovat skladové zásoby, efektivněji přizpůsobovat výrobu a optimalizovat dodávky podle očekávané poptávky.

Dalším směrem výzkumu by mohla být integrace ekonomických faktorů do prediktivních modelů. Poptávka po stavebních materiálech není závislá jen na sezónních výkyvech, ale ovlivňují ji i ceny energií, dostupnost hypoték nebo stavební legislativa. Pokud by se tyto makroekonomické ukazatele systematicky začlenily do modelů, umožnilo by to přesněji předvídat tržní trendy a upravovat skladování i cenovou strategii tak, aby odpovídaly aktuálním podmínkám na trhu.

Další důležitá oblast je vylepšení ARIMA modelu, aby byl víc flexibilní a zvládal nečekané tržní změny. Standardní ARIMA modely jsou skvělé na analýzu historických dat, ale pokud dojde k prudkému poklesu nebo růstu poptávky, jejich predikce mohou být méně spolehlivé. Adaptivní verze modelu by se dokázala automaticky upravit podle nových podmínek, což by zajistilo ještě přesnější výsledky a efektivnější řízení zásob.

Kromě toho by se dalo podívat na dlouhodobé trendy – nejen sezónní výkyvy, ale třeba i změny v preferencích zákazníků, technologické inovace nebo nové materiály, které se začínají více využívat. Pokud by se sledovalo více proměnných, predikce by byly přesnější a umožnily by firmám lépe se připravit na budoucí vývoj trhu.

Prediktivní modely by taky mohly pomoci s optimalizací logistiky, hlavně s plánováním dodávek. Pokud se propojí data o očekávané poptávce s plánováním tras pro přepravu, může to vést k rychlejším dodávkám, nižším přepravním nákladům a lepší synchronizaci skladových zásob.

Nakonec by bylo užitečné vylepšit automatizaci cenové politiky, aby firmy mohly flexibilně upravovat ceny podle očekávané poptávky a tržních podmínek. Dynamické řízení cen by umožnilo maximalizovat zisky v klíčových obdobích a zároveň udržet konkurenceschopnost i v méně aktivních sezónách.

Kombinací těchto přístupů by se prediktivní analýza posunula na ještě vyšší úroveň, což by společnosti umožnilo lépe plánovat zásoby, řídit ceny a optimalizovat logistiku.

ZÁVĚR

Tato bakalářská práce se zabývá prediktivní analýzou v logistice, konkrétně jejím praktickým využitím v podniku IM BENEFIT. V rámci výzkumu je analyzován význam prediktivní analytiky pro efektivní řízení zásob, plánování přepravy a optimalizaci podnikových procesů.

Teoretická část práce se zaměřuje na základní koncepty analytiky, její segmentaci (deskriptivní, diagnostická, prediktivní a preskriptivní analytika) a specifické metody využívané v prediktivní analýze. Mezi hlavní techniky patří regresní analýza, strojové učení, neuronové sítě a analýza časových řad. Dále jsou popsány aplikace prediktivní analytiky v různých odvětvích, jako je obchod, medicína či průmysl, a její konkrétní dopady v oblasti logistiky.

Praktická část se soustředí na konkrétní aplikaci prediktivní analýzy ve společnosti IM BENEFIT, která se zabývá stavebnictvím a prodejem stavebního materiálu. Pro účely této práce byla provedena analytická studie dvou klíčových metod: lineární regresní analýzy zaměřené na predikci rozsahu stavebních prací na základě investovaného rozpočtu a analýzy časových řad pomocí ARIMA modelu pro předpověď poptávky po stavebních materiálech.

Vedle těchto metod byla v praktické části práce realizována také série strukturovaných rozhovorů, která poskytla hlubší vhled do způsobů využití prediktivní analýzy v logistice. Tyto rozhovory byly provedeny s vedoucím skladu společnosti IM BENEFIT a zaměřovaly se na implementaci analytických modelů, optimalizaci skladových zásob, plánování přepravních tras a celkové přínosy prediktivní analýzy pro budoucnost podniku. Získané odpovědi přispěly k pochopení praktických výzev a možností, které prediktivní analytika v logistických operacích nabízí.

Použitá data pocházejí z interních databází společnosti, kde byly sledovány historické zakázky, skladové zásoby a cenové pohyby. Kromě interních zdrojů byly využity sekundární informační zdroje, jako odborné publikace a výzkumy z oblasti prediktivní analýzy.

Na základě praktické části této bakalářské práce byly stanoveny dvě výzkumné otázky a dvě hypotézy. První výzkumná otázka se zaměřuje na možnosti efektivního využití regresní analýzy k predikci rozsahu stavebních prací na základě investovaného rozpočtu. Druhá výzkumná otázka pak zkoumá přesnost modelu ARIMA při předpovědi sezónních výkyvů poptávky po stavebních materiálech. Tyto otázky reflektují klíčové aspekty

prediktivní analytiky v logistice, zejména její praktickou aplikaci v oblasti stavebnictví a řízení zásob stavebního materiálu.

V návaznosti na tyto výzkumné otázky byly formulovány dvě hypotézy. První hypotéza předpokládá existenci pozitivní korelace mezi výší investic a počtem realizovaných stavebních prací, což by mělo umožnit přesnější predikci efektivity projektového financování. Druhá hypotéza se zabývá schopností modelu ARIMA přesně předpovědět sezónní výkyvy poptávky po stavebních materiálech, což by umožnilo optimalizaci skladových zásob a řízení nákupních strategií.

Praktická část této práce se zaměřuje na kvantitativní analýzu, protože pracuje s měřeními konkrétních datových vzorců, matematickým modelováním a statistickými výpočty. Výsledky poskytují objektivní pohled na vliv prediktivní analytiky na logistické procesy, což je zásadní pro efektivní rozhodování v podnikové praxi.

SEZNAM POUŽITÉ LITERATURY

ABBOTT, Dean, 2014. *Applied predictive analytics: principles and techniques for the professional data analyst*. Indianapolis: Wiley. ISBN 978-1-118-72796-6.

AGGARWAL, Charu C., 2018. *Neural networks and deep learning: a textbook*. Cham: Springer. ISBN 978-3-319-94462-3.

BEKTEMYSOVA, Gulnara; AHMAD, Abdul Rahim; MIRZAKULOVA, Sharafat a IBRAEVA, Zhanar, 2022. *TIME SERIES FORECASTING BY THE ARIMA METHOD*. Online. *Scientific Journal of Astana IT University*. 2022-09-30, č. 11, s. 14-23. ISSN 2707-904X. Dostupné z: <https://doi.org/10.37943/HFCH4395>. [cit. 2025-04-29].

BHATIA, Parteek, 2019. *Data mining and data warehousing: principles and practical techniques*. Cambridge, United Kingdom: Cambridge University Press. ISBN 978-1-108-72774-7.

BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C. a LJUNG, Greta M., 2016. *Time series analysis: forecasting and control*. Fifth edition. *Wiley series in probability and mathematical statistics*. Hoboken: Wiley. ISBN 978-1-118-67502-1.

CAMBRIDGE ACADEMIC CONTENT DICTIONARY, 2024. *Meaning of analysis*. Online, © Cambridge University Press & Assessment. Dostupné z: <https://dictionary.cambridge.org/dictionary/english/analysis>. [cit. 2024-11-15].

FOMBU, Emmanuel, 2020. *Predictive medicine: artificial intelligence and its impact on health care business strategy*. New York: Business Expert Press. ISBN 978-1-95152-704-4.

GANGUR, Mikuláš, 2015. *Prediktivní trhy: principy, struktura a využití prediktivních trhů: pobídkové a motivační systémy prediktivních trhů: problematika implementace prediktivního trhu*. Praha: Wolters Kluwer. ISBN 978-80-7478-847-5.

KUMAR, Santhosh, 2021. *Study of risk management in logistics*. Online, In: *International Journal of Creative Research Thoughts*. ISSN: 2320-2882. Dostupné z: <https://ijcrt.org/papers/IJCRT2108043.pdf>

LEVENTHAL, Barry, 2018. *Predictive analytics for marketers: using data mining for business advantage*. London: Kogan Page. ISBN 978-0-7494-7993-0.

LIU, Huining, 2023. *Consumer Behavior Prediction in the Big Data Era: a Comparison Analysis*. Online. *BCP Business & Management*. 2023-03-02, roč. 38, s. 1055-1060. ISSN 2692-6156. Dostupné z: <https://doi.org/10.54691/bcpbm.v38i.3826>. [cit. 2025-04-11].

NELSON, Daniel, 2020. *Structured vs Unstructured Data*. Online. In: *United. AI*. 23. 8. 2020. Dostupné z: <https://www.unite.ai/structured-vs-unstructured-data/>. [cit. 2025-04-30].

ORACLE, 2021. *What Is Analytics*. Online, © Oracle. Dostupné z: <https://www.oracle.com/business-analytics/what-is-analytics/#defined>.

SAPRA, Yatin, 2025. Top Industries Benefiting from Predictive Data Analytics in 2025. Online. 6. 2.2025. Dostupné z: <https://www.hashstudioz.com/blog/top-industries-benefiting-from-predictive-data-analytics-in-2025/>. [cit. 2025-04-30].

SARSTEDT, Marko; MOOI, Erik; SARSTEDT, Marko a MOOI, Erik, 2014. *Regression Analysis*. Online. In: *A Concise Guide to Market Research. Springer Texts in Business and Economics*. Berlin, Heidelberg: Springer Berlin Heidelberg, s. 193-233. ISBN 978-3-642-53964-0. Dostupné z: https://doi.org/10.1007/978-3-642-53965-7_7. [cit. 2025-04-12].

TALEND TEAM, 2022. Embrace the Future — Make the Move From Descriptive To Prescriptive Analytics. Online. 9. 6. 2022. Dostupné z: <https://www.qlik.com/blog/embrace-the-future-moving-from-descriptive-to-prescriptive-analytics>. [cit. 2025-04-30].

TEODOROVIĆ, Dušan (ed.), 2016. *The Routledge handbook of transportation. Routledge handbooks*. New York: Routledge, Taylor & Francis Group. ISBN 978-1-138-7982-12.

TOOMBS, Gibson, 2024. *The 5 different types of data analytics (and why they're important)*. Online, In. Codal Ltd. 2. 2. 2024. Dostupné z <https://codal.com/insights/the-5-different-types-of-data-analytics-and-why-theyre-important>

WEISBERG, Sanford, 2014. *Applied linear regression. Wiley Series in Probability and Statistics*. Hoboken, New Jersey: Wiley. ISBN 978-1-118-78955-1. Dostupné také z: <https://ebookcentral.proquest.com/lib/natl-ebooks/detail.action?docID=7103845>.

SEZNAM OBRÁZKŮ

Obrázek 1: Gartnerův model analytického vzestupu (TALEND TEAM, 2022).....	17
Obrázek 2: Bodový graf zobrazující pouze dvojici s výškou matek zaokrouhlenou na 58, 64, nebo 68 palců (Weisberg, 2014, s. 3)	23
Obrázek 3: Distribuční síť pro čerstvé produkty (Kumar, 2021, s. 3).....	42
Obrázek 4: Rozložení počtu realizovaných prací podle rozpočtu (zdroj: vlastní).....	53
Obrázek 5: Lineární regrese rozpočtu a realizací (zdroj: vlastní).....	55
Obrázek 6: Příprava datasetu v pandas (zdroj: vlastní)	60
Obrázek 7: Měsíční poptávka po lepicí a stěrkové hmotě v roce 2024 (zdroj: vlastní)	61
Obrázek 8: Graf vizualizace trendů v pandas (zdroj: vlastní)	62
Obrázek 9: Testování stacionarity Dickey-Fuller testem v pandas (zdroj: vlastní).....	63
Obrázek 10: Diferenciace v případě p-hodnoty vyšší než 0,05 v pandas (zdroj: vlastní) ...	63
Obrázek 11: Aplikace ARIMA modelu v pandas (zdroj: vlastní)	63
Obrázek 12: Predikce pro rok 2025 v pandas (zdroj: vlastní)	64

SEZNAM TABULEK

Tabulka 1: Přehled menších činností s průměrnými rozpočty a popisem práce (zdroj: vlastní)	52
Tabulka 2: Vztah mezi rozpočtem projektu a počtem realizovaných prací (zdroj: vlastní)	52
Tabulka 3: Přehled měsíčních prodejů lepicí a šterkové hmoty v roce 2024 (zdroj: vlastní)	60
Tabulka 4: Odhady přínosu z jednotlivých doporučení (zdroj: vlastní)	75

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

RDC – Regionální distribuční centrum

IoT – internet věcí

ERP – Enterprise Resource Planning (podnikový informační systém)

SCM – Supply Chain Management (řízení dodavatelského řetězce)

B2B – Business-to-Business (mezi firmami)

B2C – Business-to-Consumer (mezi firmou a zákazníkem)

SME – Small and Medium-sized Enterprises (malé a střední podniky)

SOHO – Small Office/Home Office (malé kanceláře a podnikání z domova)

SQL – Structured Query Language (jazyk pro správu databází)

ARIMA – AutoRegressive Integrated Moving Average (metoda analýzy časových řad)

ACF – Autokorelační funkce

PACF – Parciální autokorelační funkce