



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV MANAGEMENTU

INSTITUTE OF MANAGEMENT

OPTIMALIZACE ZÁSOB VE VYBRANÉM PODNIKU POMOCÍ IMPLEMENTACE AI TECHNOLOGIE

INVENTORY OPTIMIZATION IN A SELECTED COMPANY BY IMPLEMENTING AI TECHNOLOGY

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. David Novobilský

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Vladimír Bartošek, Ph.D.

BRNO 2025

Zadání diplomové práce

Ústav:	Ústav managementu
Student:	Bc. David Novobilský
Vedoucí práce:	Ing. Vladimír Bartošek, Ph.D.
Akademický rok:	2024/25
Studijní program:	Strategický rozvoj podniku

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

Optimalizace zásob ve vybraném podniku pomocí implementace AI technologie

Charakteristika problematiky úkolu:

Úvod
Cíle práce, metody a postupy zpracování
Teoretická východiska práce
Analýza současného stavu
Vlastní návrhy řešení
Závěr
Seznam použité literatury
Přílohy

Cíle, kterých má být dosaženo:

Návrh implementace technologie umělé inteligence pro optimalizaci zásob v podniku.

Základní literární prameny:

EMMETT, Stuart. Řízení zásob: jak minimalizovat náklady a maximalizovat hodnotu. Brno: Computer Press, 2008. ISBN 978-80-251-1828-3.

CHUPRA, Sunil a MEINDL, Peter. Supply Chain Management Strategy, Planning, and Operation. 6th ed. Upper Saddle River: Pearson Prentice Hall, 2016. ISBN 978-0-13-380020-3.

LAMBERT, Douglas M.; STOCK, James R. a ELLRAM, Lisa M. Logistika: příkladové studie, řízení zásob, přeprava a skladování, balení zboží. 2. vyd. Brno: CP Books, 2005. ISBN 80-251-0504-0.

LUKOSZOVÁ, Xenie. Logistické technologie v dodavatelském řetězci. Praha: Ekopress, 2012. ISBN 978-80-86929-89-7.

SIXTA, Josef a ŽIŽKA, Miroslav. Logistika: metody používané pro řešení logistických projektů.
Brno: Computer Press, 2009. ISBN 978-80-251-2563-2.

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

V Brně dne 9.2.2025

L. S.

doc. Ing. Vít Chlebovský, Ph.D.
garant

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

Abstrakt

Diplomová práce se zaměřuje na optimalizaci řízení zásob ve společnosti Zebra Technologies. Práce se zabývá nastavením nových minimálních a maximálních zásob a využitím umělé inteligence pro predikci poptávky. Práce je rozdělena do tří částí. První část shrnuje teoretická východiska v oblasti řízení zásob a AI v logistice. Druhá část obsahuje analýzu současného stavu a porovnání predikčních schopností ChatGPT a Oracle Cloud. Třetí část je návrhová a prezentuje nové nastavení zásob vedoucí ke snížení kapitálu vázaného na skladových zásobách.

Abstract

The thesis focuses on inventory management optimization at Zebra Technologies. It deals with setting new minimum and maximum stock levels and using artificial intelligence for demand forecasting. The thesis is divided into three parts. The first part summarizes the theoretical background in inventory management and AI in logistics. The second part analyzes the current state and compares the predictive performance of ChatGPT and Oracle Cloud. The final part proposes new inventory settings aimed at reducing capital tied up in stock.

Klíčová slova

řízení zásob, dodavatelský řetězec, optimalizace zásob, predikce poptávky, umělá inteligence, ChatGPT, Oracle Cloud, bezpečnostní zásoba, XYZ analýza, Zebra Technologies

Key words

Inventory management, supply chain, inventory optimization, demand forecasting, artificial intelligence, ChatGPT, Oracle Cloud, safety stock, XYZ analysis, Zebra Technologies

Bibliografická citace

NOVOBILSKÝ, David. Optimalizace zásob ve vybraném podniku pomocí implementace AI technologie. Online, diplomová práce. Vladimír BARTOŠEK (vedoucí práce). Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2025. Dostupné z: <https://www.vut.cz/studenti/zav-prace/detail/165654>. [cit. 2025-04-28].

Čestné prohlášení

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

V Brně dne 28. 04. 2025

Bc. David Novobilský

autor

Poděkování

Rád bych vyjádřil své upřímné poděkování **Ing. Vladimíru Bartoškovi, Ph.D.** za jeho odborné vedení, cenné rady a trpělivost během celé práce na této diplomové práci. Jeho profesionální přístup a podpora mi pomohly nejen v odborném rozvoji, ale také v hlubším pochopení problematiky řízení zásob a optimalizace dodavatelského řetězce.

Zároveň děkuji celé společnosti Zebra Technologies za poskytnutí příležitosti realizovat tuto práci v reálném firemním prostředí. Možnost pracovat s reálnými daty a procesy v tak významné technologické firmě byla pro mě cennou zkušeností, která výrazně přispěla k odborné kvalitě této práce.

Obsah

ÚVOD	8
CÍL PRÁCE, POUŽITÉ METODY, POSTUPY A LIMITY.....	9
1 TEORETICKÁ VÝCHODISKA PRÁCE.....	10
1.1 SUPPLY CHAIN.....	10
1.1.1 <i>Stupně dodavatelského řetězce v supply chainu</i>	11
1.1.2 <i>Procesní pohled na supply chain</i>	11
1.2 TRADIČNÍ METODY ŘÍZENÍ ZÁSOB.....	13
1.2.1 <i>Metoda EOQ</i>	13
1.2.2 <i>Metoda JIT (Just In Time)</i>	16
1.2.3 <i>Metoda ABC</i>	17
1.2.4 <i>Metoda XYZ</i>	18
1.3 MODERNÍ METODY ŘÍZENÍ ZÁSOB	19
1.3.1 <i>MRP systém řízení zásoby</i>	19
1.3.2 <i>ERP systém řízení zásob</i>	20
1.3.3 <i>RFID a IoT</i>	21
1.3.4 <i>Kanban</i>	23
1.4 PREDIKTIVNÍ ANALYTIKA	23
1.5 UMĚLÁ INTELLIGENCE	25
1.5.1 <i>Historie AI</i>	26
1.5.2 <i>Fungování AI</i>	27
1.5.3 <i>Typy umělé inteligence</i>	27
1.5.4 <i>Treninkové modely umělé inteligence</i>	28
1.6 UMĚLÁ INTELLIGENCE V SUPPLY CHAINU	29
1.7 RIZIKA VYUŽITÍ UMĚLÉ INTELLIGENCE	30
2 ANALÝZA SOUČASNÉHO STAVU	32
2.1 PŘEDSTAVENÍ SPOLEČNOSTI	32
2.1.1 <i>Historie společnosti</i>	33
2.1.2 <i>Struktura společnosti</i>	35
2.1.3 <i>Zákazníci</i>	36
2.1.4 <i>Finační výsledky firmy</i>	37
2.1.5 <i>Informační systém</i>	38
2.2 SUPPLY CHAIN – ZEBRA TECHNOLOGIES	39
2.2.1 <i>Organizační struktura a role v oddělení</i>	40

2.2.2	<i>Hlavní procesy a jejich průběh</i>	40
2.2.3	<i>Používané technologie a systémy</i>	43
2.2.4	<i>Efektivita a výkoností ukazatele</i>	43
2.3	IDENTIFIKACE A ANALÝZA ŘÍZENÍ ZÁSOB V ZEBRA TECHNOLOGIES	44
2.4	ANALÝZA POUŽÍVANÝCH DAT	46
2.4.1	<i>Parts hold report</i>	46
2.4.2	<i>Plan for Every Part report (PFEP)</i>	46
2.5	ANALÝZA MODELŮ UMĚLÉ INTELIGENCE VYUŽÍVATELNÉ PRO SUPPLY CHAIN	48
2.6	METODOLOGIE HODNOCENÍ UMĚLÉ INTELIGENCE	51
2.7	IDENTIFIKACE OBLASTÍ APLIKACE AI V SUPPLY CHAIN MANAGEMENTU	53
2.8	ANALÝZA RIZIK UMĚLÉ INTELIGENCE	57
2.9	PŘÍKLADY ÚSPĚŠNÝCH IMPLEMENTACÍ AI V SUPPLY CHAINU	60
3	VLASTNÍ NÁVRHY ŘEŠENÍ	63
3.1	PREDIKTIVNÍ ANALÝZA DAT	63
3.1.1	<i>Ekonomické zhodnocení</i>	65
3.2	OPTIMALIZACE ZÁSBOVÝCH HODNOT	66
3.2.1	<i>Ekonomické zhodnocení</i>	71
3.2.2	<i>Využití umělé inteligence v rámci optimalizace zásobových hodnot</i>	75
	ZÁVĚR	76
	SEZNAM OBRÁZKŮ	77
	SEZNAM ZKRATEK	78
	SEZNAM TABULEK	78
	SEZNAM ROVNIC	78
	SEZNAM PŘÍLOH	78
	SEZNAM ZDROJŮ	79

Úvod

V dnešní době, kdy se globální trhy neustále mění a podniky čelí rostoucím nárokům na efektivitu, hraje řízení dodavatelského řetězce klíčovou roli v úspěchu firem. Optimalizace zásob a predikce poptávky se staly nezbytnými faktory pro udržení konkurenceschopnosti a snížení provozních nákladů. Tato diplomová práce se zaměřuje na analýzu a zlepšení řízení zásob ve společnosti Zebra Technologies, přičemž klíčovým prvkem optimalizace je využití umělé inteligence (AI).

Práce je rozdělena do několika částí. V teoretické části je popsána problematika řízení zásob a moderní metody jejich optimalizace, včetně klasických přístupů, jako jsou metody EOQ, JIT, ABC a XYZ. Analytická část se věnuje současnému stavu zásobování ve společnosti Zebra Technologies, identifikaci klíčových problémů a analýze historických dat o spotřebě. Následně je provedeno testování predikčních schopností umělé inteligence a výpočty nových hodnot zásob s cílem optimalizace skladových procesů.

Výsledky této studie mají potenciál přispět nejen k efektivnějšímu řízení zásob ve firmě Zebra Technologies, ale mohou také sloužit jako příklad pro další společnosti, které hledají inovativní přístupy k predikci poptávky a optimalizaci skladových zásob prostřednictvím umělé inteligence.

Cíl práce, použité metody, postupy a limity

Cílem této diplomové práce je optimalizace nastavení skladových zásob ve společnosti Zebra Technologies. Tato optimalizace má vést ke snížení nadbytečných skladových zásob, zároveň tato práce zkoumá využití umělé inteligence v rámci zlepšení předpovědi poptávky na základě hodnot spotřeby z minulosti.

Pro dosažení cíle byly využity následující metody:

- Analýza historické spotřeby jednotlivých položek (za období 6 měsíců)
- Výpočet bezpečnostní zásoby a následné stanovení nových minimálních a maximálních hladin zásob
- Zařazení položek do XYZ klasifikace
- Porovnání přesnosti modelů umělé inteligence
- Porovnání výsledků umělé inteligence se současným nástrojem pro předpověď poptávky firmy Zebra Technologies
- Vyhodnocení rozdílů mezi stávajícím a navrženým nastavením

Limity práce

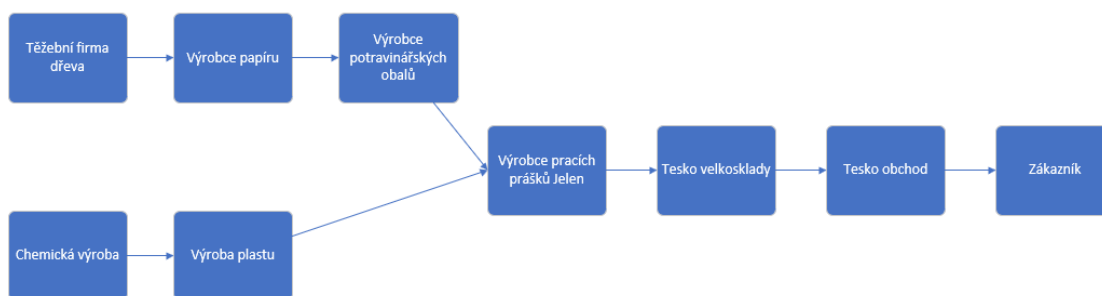
Práce je omezena několika faktory. Především se opírá o historická data za období pouze šesti měsíců, což může ovlivnit přesnost predikcí u položek s nepravidelným pohybem. Dále nebyly zohledněny všechny externí faktory (např. sezónnost, změny ve výrobě nebo na trhu). Dalším faktorem je, že vybraný vzorek se vztahuje pouze na výrobní rodinu TC21, která může nebo naopak nemusí mít lepší stabilitu poptávky oproti rodinám ostatním. Navrhované hladiny zásob také neberou v plné míře v potaz specifické požadavky zákazníků nebo dlouhodobé strategické cíle společnosti.

1 Teoretická východiska práce

1.1 Supply Chain

Supply Chain neboli česky řečeno dodavatelský řetězec představuje systém který zahrnuje všechny subjekty zapojené do splnění požadavku zákazníka, a to jak přímo, tak nepřímo. V tomto systému nenajdeme jen výrobce a dodavatele, ale i přepravce, sklady, maloobchodníky, a dokonce samotné zákazníky. Uvnitř každé organizace (např. u výrobce) se dodavatelský řetězec skládá ze všech funkcí, které se podílejí na přijetí a vyřízení objednávky. Mezi tyto funkce patří třeba vývoj nových produktů, marketing, distribuce, provoz, finance a zákaznický servis. (Chopra, Meindla, 2016, str. 13-15)

Pro lepší představu můžeme vzít příklad z každodenního života. Když zákazník vejde do prodejny Tesca a koupí si prací prostředek, celý dodavatelský řetězec začíná právě u tohoto zákazníka a jeho potřeby po tomto produktu. Tesco má v regálech zboží, které mohlo být dodáno z distribučního centra, nebo přímo od výrobce. Výrobce pak vyrábí tento prací prostředek díky surovinám, které získává od různých dodavatelů. Někteří z těchto dodavatelů mohou být zásobováni ještě dalšími subdodavateli. Tento celý proces ukazuje, jak propojené jsou jednotlivé články dodavatelského řetězce.



Obrázek 1 Návrh příkladu dodavatelského řetězce (Zdroj: vlastní zpracování podle Chopra, Meindla, str 14, 2024)

Jednou z hlavních funkcí dodavatelského řetězce je uspokojit potřeby zákazníků a současně generovat zisk. Možná se Vám při termínu "dodatelský řetězec" vybaví jen to, jak se produkt pohybuje od dodavatele k výrobcovi, distributorovi, a nakonec k

zákazníkovi, ale tento systém zahrnuje mnohem víc. Jde i o tok informací a financí, který probíhá v obou směrech. Ačkoliv se termín "řetězec" často používá, ve skutečnosti jde spíš o dodavatelskou síť, protože v realitě výrobci spolupracují s několika dodavateli a dodávají své produkty více distributorům. (Chopra, Meindla, 2016, str. 13-15)

1.1.1 Stupně dodavatelského řetězce v supply chainu

Každý dodavatelský řetězec se skládá z několika úrovní, které mohou zahrnovat:

- Zákazníky
- Maloobchodníky
- Velkoobchodníky/distributory
- Výrobce
- Dodavatele surovin nebo komponentů

Každá z těchto úrovní je propojena toky produktů, informací a financí, které proudí v obou směrech. Způsob, jakým je tento řetězec navržen a řízen, závisí na potřebách zákazníka a rolích jednotlivých subjektů. Některé dodavatelské řetězce mohou být poměrně jednoduché, zatímco jiné jsou složitější a zahrnují více mezičlánků. (Chopra, Meindla, 2016, str.15)

1.1.2 Procesní pohled na supply chain

Dodatelský řetězec je tvořen řadou různých procesů a toků, které probíhají jak mezi jednotlivými stupni, tak uvnitř nich, a jejich hlavním cílem je naplnit potřeby zákazníka.

Na tyto procesy se můžeme dívat dvěma základními způsoby:

Cyklus pohled: Zde jsou procesy rozděleny do jednotlivých cyklů, přičemž každý z nich probíhá mezi dvěma sousedními stupni dodavatelského řetězce.

Push/pull pohled: Tento způsob rozlišuje procesy na základě toho, zda jsou vykonávány v reakci na konkrétní objednávku zákazníka (pull) nebo na základě předpokládané

poptávky (push). Pull procesy začínají až po objednávce, zatímco push procesy jsou zahájeny předem, ještě před tím, než zákazník objedná.

Cyklus pohled na procesy v Supply chainu

Pokud se podíváme na celý dodavatelský řetězec, který může zahrnovat například zákazníka, distributory, výrobce a dodavatele surovin, můžeme rozdělit všechny procesy do čtyř základních cyklů:

- Cyklus zákaznické objednávky
- Cyklus doplnění zásob
- Výrobní cyklus
- Nákupní cyklus

Každý z těchto cyklů probíhá mezi dvěma sousedními články řetězce. Ne všechny dodavatelské řetězce mají tyto cykly jasně oddělené. Například v maloobchodě jsou všechny cykly obvykle zřetelně oddělené, zatímco u společností, které prodávají přímo zákazníkům, může být některé z těchto cyklů možné přeskočit.

Každý cyklus začíná tím, že dodavatel prezentuje produkt kupujícímu, který následně zadává objednávku. Ta je přijata a zpracována dodavatelem, který zajistí dodání produktu. Kupující může případně vrátit část zboží nebo obalový materiál. Tento proces se poté opakuje. Jednotlivé cykly mají za cíl zajistit efektivní a hladký tok produktů a informací v rámci řetězce.

Cílem každého cyklu je zlepšit dostupnost produktů pro zákazníka a současně snížit náklady spojené s objednávkami. Dodavatelé se snaží co nejlépe předpovědět budoucí objednávky a optimalizovat jejich zpracování, zatímco kupující se zaměřují na snížení nákladů na příjem zboží a jeho manipulaci.

Ačkoliv se jednotlivé cykly ve své podstatě podobají, existují mezi nimi zásadní rozdíly. Například v cyklu zákaznické objednávky je poptávka zcela neznámá a závisí na zákaznících. V ostatních cyklech lze objednávky lépe předvídat na základě interních

procesů. Dalším rozdílem je velikost objednávek – zákazník objednává jednotlivé produkty, zatímco prodejci nebo distributoři objednávají mnohem větší objemy najednou. Detailní pohled na procesy v rámci jednotlivých cyklů je velmi užitečný při rozhodování o provozních záležitostech. Tento přístup pomáhá lépe pochopit role jednotlivých článků řetězce a je často využíván v podnikovém plánování a řízení zásob. (Chopra, Meindla, 2016, str. 13-20)

1.2 Tradiční metody řízení zásob

Řízení zásob je jednou z klíčových oblastí, která ovlivňuje efektivitu a konkurenceschopnost podniku. V průběhu let se vyvinulo mnoho metod a přístupů, které se zaměřují na optimalizaci zásobovacích procesů. Tradiční metody řízení zásob, jako jsou EOQ, JIT, ABC nebo XYZ, tvoří základ pro moderní logistické a zásobovací systémy. Tyto metody se zaměřují na snižování nákladů, minimalizaci plýtvání a zajištění plynulého toku materiálů.

1.2.1 Metoda EOQ

Economic Order Quantity pod českým pojmenováním ekonomická objednávací velikost je klíčový model používaný v řízení zásob, který pomáhá určit optimální velikost objednávek. Jeho cílem je minimalizovat celkové náklady spojené s objednáváním a skladováním zásob. Model EOQ odpovídá na otázku: „*Jak velkou objednávku bychom měli učinit, abychom snížili náklady na minimum?*“

Princip fungování EOQ

EOQ pracuje s předpokladem ideálního systému zásobování, ve kterém hledáme optimální velikost objednávky, která snižuje celkové náklady spojené s držbou a zadáváním objednávek. Tato optimální objednávková velikost je známá jako ekonomická objednávací velikost (EOQ). I přes svou jednoduchost je model EOQ hojně využíván, protože nabízí praktické řešení i pro složitější systémy zásobování.


Historicky byl model představen Harrisem v roce 1915, ale často je připisován Wilsonovi, který jej v roce 1934 znovu zpopularizoval. Přestože se jedná o starší metodu, její využití je stále aktuální a přináší dobré výsledky v oblasti řízení zásob. (Waters, 2003, str 65-66)

Předpoklady modelu EOQ

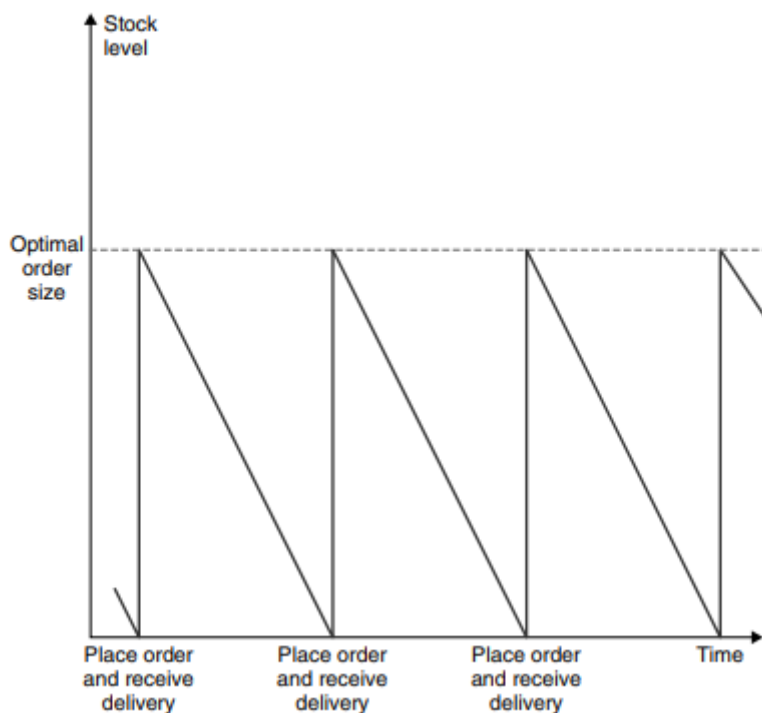
Aby byl model EOQ funkční, je založen na několika předpokladech, které zjednodušují jeho aplikaci:

- **Konstantní a předvídatelná poptávka:** Předpokládá se, že poptávka je konstantní a dobře známá, což znamená, že zásoby se spotřebovávají rovnoměrně.
- **Fixní náklady:** Náklady spojené s objednáním a skladováním jsou stabilní a nemění se v čase.
- **Nedostatek zásob není povolen:** Model předpokládá, že nedochází k vyčerpání zásob, čímž se zamezuje ztrátě prodeje.
- **Okamžitá dostupnost zásob:** Dodací lhůty jsou nulové, což znamená, že zásoby jsou k dispozici okamžitě po objednání.

Tyto předpoklady zjednodušují řízení zásob, kdy zásoby postupně klesají až k bodu, kdy je zadána nová objednávka, a tento proces se neustále opakuje. Tento ideální systém předpokládá, že objednávky jsou realizovány v přesně stanovených intervalech a vždy v optimálním množství.



Obrázek 2 EOQ – Model počítá s konstantní poptávkou v průběhu času (Zdroj: Waters, str 68)



Obrázek 3 Úroveň zásob s pevnou velikostí objednávky (Zdroj: Waters, str. 68)

Výhody a omezení EOQ

Jednou z hlavních výhod EOQ je jeho jednoduchost a přehlednost. Model umožňuje rychle vypočítat optimální velikost objednávky a tím snížit náklady na skladování i objednávání. Ačkoli nebere v úvahu složitější faktory, jako jsou kolísající poptávka nebo proměnlivé náklady, je stále velmi praktický a široce použitelný v podnikové praxi.

Mezi hlavní nevýhody patří skutečnost, že předpokládá stabilní podmínky – konstantní poptávku a náklady, což v reálném světě není vždy možné. EOQ také nepočítá s reálnými dodacími lhůtami, které mohou ovlivnit dostupnost zásob v různých časových obdobích. (Waters, 2003, str 66-67)

Vzorec EOQ

EOQ má přesně stanovený vzorec ve tvaru:

$$EOQ = \sqrt{\frac{2DS}{H}}$$

Rovnice 1: Výpočet EOQ

Kdy jednotlivé zkratky znamenají:

- D – poptávka za jeden rok
- S – náklady na jednu objednávku

H – náklady spojené se skladováním jednotek za rok

Praktická aplikace EOQ

I přes zjednodušené předpoklady se EOQ často používá v řadě oblastí, například ve výrobních podnicích s předvídatelnou poptávkou. Pomáhá firmám optimalizovat zásobovací procesy a snižovat náklady. EOQ se často používá jako výchozí model, který lze rozšířit a přizpůsobit konkrétním potřebám daného podniku.

Díky své jednoduchosti a praktičnosti je EOQ stále důležitým nástrojem v řízení zásob a slouží jako základ pro složitější modely, které řeší více faktorů ovlivňujících zásoby. (Waters, 2003, str 66-68)

1.2.2 Metoda JIT (Just In Time)

Tato technologie patří mezi nejdůležitější a nejpoužívanější v oblasti logistiky a lze ji uplatnit jak v oblasti zásobování, tak ve výrobě i distribuci v rámci celého logistického řetězce. Pokud by byla zavedena napříč všemi těmito částmi, výrazně by to posílilo konkurenceschopnost celého dodavatelského řetězce, a to zejména díky vyšší flexibilitě, kvalitě a efektivitě. (Lukoszová, 2012, str. 14)

JIT je metoda, která spočívá v tom, že potřeba po určitém materiálu, součástkách nebo hotových výrobcích je uspokojována jejich dodáním „právě včas“. To znamená, že dodávky jsou realizovány přesně ve chvíli, kdy je odběratel potřebuje, na základě předem dohodnutých termínů.

Charakteristické pro tuto metodu jsou:

- Dodávky malých množství, co nejpozději, aby se minimalizovaly zásoby
- Časté dodávky
- Dodávky jsou prováděny přesně ve chvíli, kdy je poptávka aktuální, což znamená, že odběratel je dominantní částí řetězce a nedochází u něj ke kumulaci zásob (Cempírek, 2014, str. 24)

Tato metoda je zaměřena na snižování zásob a zajištění včasného zásobování podniků. Podniky, které tuto metodu využívají, se soustředí především na odstranění prostojů a časových ztrát, což znamená, že hlavním cílem této technologie je minimalizace plýtvání. Při hledání úspor je důležité rozlišovat mezi časem potřebným pro samotnou výrobu a časem potřebným pro realizaci.

Čas realizace je definován jako období od začátku zpracování materiálu až po okamžik, kdy podnik obdrží platbu za hotový produkt. K tomu se připočítává i čas na skladování, který společně s výrobním časem tvoří celkový realizační čas. Často se stává, že produkt stráví více času ve skladu než v samotné výrobě, což naznačuje, že právě skladování představuje největší prostor pro úspory. Zkrácením realizačního času se sníží počet činností, které nepřidávají hodnotu, a tím je jednodušší odhalit problémy v procesu. (Lukoszová, 2012, str. 30-31)

1.2.3 Metoda ABC

ABC metoda je systém segmentace, který slouží ke zlepšení procesu nákupu. Tato metoda klasifikuje jednotlivé položky na základě objemu nákupů nebo spotřeby vyjádřené v penězích. ABC analýza vychází z Paretova pravidla, které říká, že 20 % příčin způsobuje 80 % výsledků. V kontextu nákupu to znamená, že 20 % nakoupených položek představuje 80 % nákladů na nákup nebo hodnoty spotřeby. (Cavinato, Kauffman, 2000, str. 81)


Paretův princip je pojmenován po italském sociologovi a ekonomovi Vilfredu Paretovi, který na základě svého výzkumu o rozdělení majetku zjistil, že přibližně 20 % obyvatel vlastní 80 % veškerého majetku. Toto pravidlo pak lze podobně uplatit i u třídění zásob. Můžeme tedy částečně říct, že metoda ABC vychází u tohoto pravidla. (Lambert, Ellram, Stock, 2005, s. 170)

Zakoupené položky jsou na základě analýzy rozděleny do tří skupin podle jejich významu. Skupina A obsahuje malý počet položek s vysokou obrátkovostí a velkým podílem na celkovém objemu. Skupina B zahrnuje položky se střední obrátkovostí a

průměrným objemem. Skupina C zahrnuje velký počet položek, které mají nízkou obrátkovost a malý objem. V některých případech je možné analýzu rozšířit o další klasifikační úrovně.

Procentuální rozdělení položek mezi jednotlivé skupiny není pevně dáno a závisí na rozhodnutí osoby provádějící analýzu. Obvykle bývá rozložení následující:

- **A:** 10 % položek tvoří 70 % hodnoty spotřeby,
- **B:** 25 % položek odpovídá za 20 % hodnoty spotřeby,
- **C:** 65 % položek představuje pouze 10 % hodnoty spotřeby (Emmett, 2008, s. 39).



Obrázek 4: Lorenzova křivka (Zdroj: Sixta, Žižka, 2009)

1.2.4 Metoda XYZ

XYZ metoda je analytický nástroj, který slouží k segmentaci položek zásob podle jejich spotřeby v čase. Cílem je rozlišit materiály, které jsou spotřebovávány pravidelně, od těch, jejichž spotřeba kolísá nebo je nepravidelná.

Položky jsou rozděleny do tří skupin:

- **X:** Jedná se o položky s pravidelnou a stabilní spotřebou, kde jsou výkyvy minimální. Tyto položky jsou zpravidla snadno predikovatelné a dobře se plánují.
- **Y:** Tato kategorie zahrnuje položky, jejichž spotřeba vykazuje značné výkyvy, což ztěžuje jejich předpověď. U těchto položek je třeba pečlivě sledovat zásoby a reagovat na změny.
- **Z:** Položky v této skupině mají nepravidelnou, nevyzpytatelnou spotřebu. Tyto položky mohou být méně časté, ale jejich řízení je náročnější kvůli obtížné předpovědi poptávky.

Toto rozdělení umožňuje lepší pochopení a řízení zásob podle chování jejich spotřeby. (Pernica, Řezníček, 2005, s. 323)

1.3 Moderní metody řízení zásob

S rychlým rozvojem technologií a zvyšujícími se nároky na efektivitu se tradiční přístupy k řízení zásob postupně přetvářejí do modernějších a sofistikovanějších metod. Moderní metody řízení zásob integrují pokročilé technologie, automatizaci a data v reálném čase, aby umožnily flexibilnější a přesnější plánování. Tyto přístupy se nezaměřují pouze na optimalizaci skladových procesů, ale také na zlepšení celkového fungování dodavatelského řetězce.

1.3.1 MRP systém řízení zásoby

Material Requirements Planning je klíčový systém pro řízení zásob a výroby v dodavatelském řetězci. Jeho hlavním cílem je zajistit, aby byly potřebné materiály k dispozici v dostatečném množství a včas pro výrobu, a zároveň aby byly hotové výrobky připraveny k dodání zákazníkům. MRP koordinuje procesy nákupu, výrobních harmonogramů a časových plánů dodávek, čímž optimalizuje tok materiálů. Hlavními prvky MRP jsou kontrola zásob, kusovníky a hlavní výrobní plánování. Tímto způsobem MRP pomáhá firmám snižovat plýtvání, zlepšovat efektivitu výroby a lépe reagovat na požadavky zákazníků.

V kontextu řízení dodavatelského řetězce MRP zajišťuje, že materiály jsou dostupné tehdy, kdy jsou potřeba, a zároveň pomáhá efektivně spravovat zásoby. Tento systém propojuje nabídku materiálů s výrobními plány, což firmám umožňuje předcházet nadprodukcí a výpadkům zásob. MRP pracuje na základě dat, jako jsou kusovníky, úrovně zásob a výrobní plány, a pomáhá určit, kdy a v jakém množství je třeba materiály objednat. Tím se lépe synchronizuje poptávka s nabídkou, což zkracuje dodací lhůty a zvyšuje efektivitu operací.

Jednou z hlavních funkcí MRP je optimalizace řízení zásob. Systém vypočítává přesné množství materiálů potřebných v každé fázi výroby, čímž pomáhá výrobcům vyhnout se nadměrnému skladování, což snižuje náklady na skladování a minimalizuje plýtvání. Současně MRP zajišťuje, že klíčové materiály jsou vždy k dispozici, čímž se snižuje riziko zpoždění výroby kvůli nedostatku zásob. Tento proces neustále aktualizuje informace o zásobách, čímž poskytuje manažerům dodavatelského řetězce v reálném čase přehled o stavu zásob a umožňuje jim efektivněji plánovat objednávky.

Implementace MRP přináší řadu výhod, včetně lepšího řízení zásob a výroby, snížení plýtvání a zlepšení komunikace mezi odděleními. Na druhou stranu může být zavedení MRP náročné, vyžaduje přesná data a správné nastavení systému. Pokud nejsou data správná, může dojít k chybám v plánování, což vede k problémům s dodávkami nebo nadbytečnými zásobami. Přesto je MRP zásadním nástrojem pro firmy, které chtějí zefektivnit své operace a zlepšit své konkurenční postavení na trhu.

(Zdroj: Indmall Automation, 2025).

1.3.2 ERP systém řízení zásob

ERP systémy lze popsat jako softwarové balíky složené z několika modulů. Jejich hlavním účelem je integrovat klíčové firemní procesy, jako jsou mzdy, personalistika, výroba nebo zásobování, do jednoho centralizovaného systému, který využívá jednotnou databázi. To umožňuje efektivnější a spolehlivější sdílení informací mezi zaměstnanci napříč celou organizací. (Gála, 2015, str. 100).

Jednou z klíčových funkcí ERP systému je podpora všech procesů v logistickém řetězci. Například systém zpracovává už samotné přijetí objednávky, spravuje a analyzuje stav skladových zásob, zpracovává požadavky na objednání zboží od dodavatelů, plánuje a vyhodnocuje výrobní kapacity a také ukládá data související s logistickým řetězcem.

(Basl a Blažíček, 2012, s. 69)

Základní rozdělení ERP systémů se odvíjí od toho, v jakém rozsahu dokáží plnit základní funkce

All-in-one systémy pokrývají všechny hlavní funkce pomocí jednoho softwaru. Jejich hlavní výhodou je vysoká úroveň integrace, ale jejich nevýhodou je nižší míra funkcionality

Best-of-Breed systémy nejsou navrženy tak, aby pokrývaly všechny funkce, ale zaměřují se na specifické procesy nebo odvětví. Výhodou je vysoká úroveň funkcionality, ale nevýhodou je složitější sjednocení procesů

Lite ERP systémy jsou určeny pro malé a střední podniky. Jejich hlavní výhodou je cenová dostupnost, ale na druhou stranu mají omezenou funkcionalitu (Sodomka a Klčová, 2010, s. 149-150)

1.3.3 RFID a IoT

RFID

Obecně platí, že k tomu, abychom efektivně využívali nějakou technologii, je nejprve potřeba ji dobře pochopit. Technologie radiofrekvenční identifikace (RFID) spadají do skupiny tzv. automatických informačních technologií (AIT), které představují složité systémy s mnoha způsoby využití. V tomto textu se zaměřujeme na dvě rozšířené technologie – RFID a čárové kódy. Proto tato kapitola popisuje AIT technologie a poskytuje historický přehled o vývoji čárových kódů a RFID. (Zdroj: Jones a Chung, 2017, Str 33)

RFID je obecný termín, který popisuje systém, jenž bezdrátově přenáší identitu objektu nebo osoby (ve formě unikátního sériového čísla) pomocí rádiových vln. RFID spadá do širší kategorie automatických informačních technologií (AIT). RFID technologie nás obklopuje všude kolem. Navíc se RFID stále více kombinuje s biometrickými technologiemi pro účely bezpečnosti. Na rozdíl od rozšířené technologie čárových kódů (UPC), RFID nevyžaduje fyzický kontakt ani přímou viditelnost pro přenos dat. RFID dokáže číst data i skrz lidské tělo, oblečení nebo nemetalické materiály. (Zdroj: Jones a Chung, 2017, str 66)

Internet of Things

IoT v dodavatelském řetězci přináší revoluční změny tím, že propojuje různá zařízení a senzory pro sběr a analýzu dat v reálném čase. IoT umožňuje sledování zboží od výroby až po doručení, což zajišťuje vyšší transparentnost a efektivnější řízení procesů. Sledování pohybu zásilek pomocí GPS a senzorů umožňuje rychlou reakci na problémy, jako jsou zpoždění nebo odchylky od trasy, což pomáhá předcházet ztrátám a zpožděním.

IoT rovněž pomáhá při monitorování skladovacích podmínek, což je klíčové pro zboží citlivé na teplotu či vlhkost. Díky přesným údajům o teplotě nebo vlhkosti lze minimalizovat riziko poškození zboží. Kromě toho IoT zlepšuje plánování tras a odhady času doručení tím, že analyzuje dopravní situaci a další faktory, což umožňuje lepší řízení logistiky.

Další velkou výhodou IoT je automatizace a optimalizace procesů. IoT zařízení v kombinaci s technologií RFID pomáhají efektivněji spravovat skladové zásoby a zjednodušují vyhledávání zboží ve skladech. To nejen zvyšuje produktivitu, ale také snižuje náklady spojené se skladováním a zajišťuje lepší kontrolu nad celým dodavatelským řetězcem.

(Zdroj: Rishabh Software, 2023)

1.3.4 Kanban

Zatímco systémy řízení zakázek zaměřené na optimalizaci zatížení se snaží zlepšit provoz na úrovni centrálního řídicího systému, přičemž samotný výrobní tok zůstává beze změny, japonský systém kanban, který zavedla firma Toyota, se soustředí na efektivní řízení toku ve výrobním procesu.

Hlavním cílem je schopnost rychlého dodání na pracoviště, aby se minimalizovaly ztráty během výrobního procesu. Tato metoda se používá především ve velkosériové a hromadné výrobě, která je organizována jako proudová výroba, protože zde existuje pevně daný a stálý vztah mezi jednotlivými pracovišti. Dalšími požadavky jsou standardizace výrobního programu a sladění výrobního taktu.

(Gustav, Vávrová, 2014, str 885-886)

Kanban poskytuje způsob, jak řídit tok materiálu do a skrz výrobní proces. Tento materiál může zahrnovat suroviny, díly, komponenty a podsestavy, a to jak ty, které jsou vyráběny interně, tak i ty nakupované od externích dodavatelů. Hlavní prvky kanban systému zahrnují následující otázky:

- Co je potřeba přemístit
- Kdy to přemístit
- Jaké množství přemístit
- Odkud a kam to přemístit

(Cimorelli, 2016, str 2-3)

1.4 Prediktivní analytika

Analytika je proces, při kterém se využívají výpočetní metody k objevování a interpretaci klíčových vzorců v datech. Jejím cílem je získat vhled, který často ovlivňuje rozhodování. Data, která analytika zkoumá, vždy vycházejí z historických informací, což znamená, že analytika se primárně zabývá analýzou historických dat. Termín "analytika" se stal populárním v roce 2005, a to především díky zavedení nástroje Google Analytics. Nicméně samotné myšlenky stojící za analytikou nejsou nové, byly v průběhu desetiletí


označovány různými termíny, jako například kybernetika, analýza dat, neuronové sítě, rozpoznávání vzorců, statistika, získávání znalostí, datová těžba a dnes i datová věda.

Popularita analytiky v posledních letech je praktická: jak organizace shromažďují více dat a začínají je shrnovat, přirozeně směřují k tomu, aby tato data využívaly ke zlepšení odhadů, prognóz, rozhodování a v konečném důsledku i ke zvýšení efektivity. (Abbott, 2014, str 3)

Za prvé, prediktivní analytika je založená na datech, což znamená, že algoritmy vytvářejí hlavní charakteristiky modelů přímo z dat, nikoli na základě předpokladů analytika. Jinými slovy, data-driven algoritmy vytvářejí modely na základě samotných dat. Tento proces zahrnuje výběr proměnných, parametry modelu, váhy či koeficienty a celkovou složitost modelu.

Za druhé, algoritmy prediktivní analytiky automatizují hledání vzorců v datech. Silné indukční algoritmy nejenže nacházejí koeficienty a váhy pro modely, ale také samy určují strukturu modelu. Například algoritmy pro rozhodování identifikují, které vstupy nejlépe předpovídají cílovou proměnnou a také určují, které hodnoty těchto proměnných jsou pro předpovědi nejvhodnější. Některé algoritmy také provádějí vyčerpávající nebo "chamtivé" hledání, aby našly nejlepší sadu vstupů a parametrů modelu. Pokud určitá proměnná pomáhá snižovat chybu modelu, je do něj zahrnuta.

Prediktivní algoritmy prohledávají všechny možné kombinace vstupních proměnných a identifikují ty nejdůležitější. Analytik se pak může zaměřit jen na tyto klíčové vzorce, což výrazně zjednoduší celý proces. Místo analyzování téměř 20 000 kombinací vám prediktivní model může naznačit, že pouze šest proměnných významně přispívá k přesnosti modelu, z toho tři jsou zvláště dobrými prediktory. To vám zmenší počet grafů, na které se zaměřit, ze skoro 20 000 na 63. Právě v tom spočívá jedna z nejsilnějších stránek prediktivní analytiky: identifikace nejdůležitějších vstupů v datech. (Abbott, 2014, str 3-5)



Obrázek 5: Histogram (Zdroj: Abbott, 2014, str. 4)

Business Intelligence

Business intelligence je rozsáhlá oblast, která je tématem celých knih; zde se stručně shrnou její hlavní charakteristiky ve vztahu k prediktivní analytice. Výstupem mnoha analýz business intelligence jsou zprávy nebo dashboardy, které shrnují důležité charakteristiky dat, často označované jako klíčové ukazatele výkonnosti (KPIs). KPI reporty jsou většinou vytvářeny na základě požadavků uživatele, kdy analytik nebo rozhodovatel určí, které ukazatele jsou pro podnik klíčové. Tyto reporty mohou obsahovat jednoduché souhrny nebo složitá vícerozměrná měření.

Je zajímavé, že pojem KPI se téměř nikdy nepoužívá k popisu metrik v rámci prediktivní analytiky nebo na odborných konferencích. Typickým výstupem business intelligence je zpráva určená pro analytiky a manažery. (Abbott, 2014, str 6)

1.5 Umělá inteligence

Umělá inteligence často zmiňovaná ve zkratce AI (Artificial intelligence) zahrnuje sadu technologií, které umožňují počítačům vykonávat různé pokročilé funkce, jako je rozpoznávání a analýza obrazu, zpracování a překlad mluveného i psaného jazyka, analýza dat a vytváření doporučení. AI je základem moderních inovací v oblasti výpočetní techniky a přináší hodnotu jak jednotlivcům, tak firmám. Například technologie pro optické rozpoznávání znaků využívá AI k extrakci textu a dat z obrázků

a dokumentů, čímž převádí nestrukturovaný obsah do strukturovaných dat připravených pro firemní využití.

Umělá inteligence je široký obor, který se zabývá vývojem počítačů a strojů schopných uvažovat, učit se a jednat způsobem, který by normálně vyžadoval lidskou inteligenci, nebo zpracovávat data, jejichž rozsah přesahuje lidské možnosti. Tento obor zahrnuje mnoho disciplín, včetně informatiky, datové analytiky, statistiky, softwarového a hardwarového inženýrství, lingvistiky, neurovědy a dokonce i filozofie a psychologie.

Z praktického hlediska, zejména v podnikání, je AI sada technologií založených především na strojovém učení a hlubokém učení, které se využívají pro analýzu dat, predikce, kategorizaci objektů, zpracování přirozeného jazyka, inteligentní vyhledávání a další aplikace. (Russell, 2016)

1.5.1 Historie AI

V roce 1956 John McCarthy z MIT zorganizoval konferenci na Dartmouth College v New Hampshire, na kterou pozval špičkové odborníky. Ti měli za úkol přispět k výzkumu strojového modelování úloh zaměřených na kognitivní a mentální činnosti člověka. Během této konference McCarthy navrhl pojmenování nového vědního oboru jako umělá inteligence, což bylo přijato a tento termín se ujal.

O rok později byl představen systém GPS (General Problem Solver), který vytvořili A. Newell, R. Solomonoff a H. Simon. Tento systém byl koncipován jako univerzální nástroj pro řešení úloh napříč různými oblastmi, založený na manipulaci se symboly a matematickou logikou. Ukázalo se však, že jeho praktické využití je omezené a nepříliš pružné.

Podobně jako v případě termínu umělá inteligence dosud neexistuje univerzálně přijatá definice pro tento pojem. Přesto se pro umělou inteligenci stanovily určité charakteristiky, které by měla splňovat. Podle hypotézy formulované v roce 1956 (Newell, Simon) lze umělou inteligenci definovat jako schopnost pracovat se symboly a vytvářet kvalitativní struktury, které pomáhají získávat a reprezentovat detailnější znalosti.

V té době také Marvin Minsky navrhl koncept rámce pro datové struktury, který popisuje konkrétní oblast zájmu v počítačových programech. Rámce se obvykle používají pro stereotypní situace a objekty, které lze dále zkoumat a upravovat. Tato myšlenka vedla k vývoji objektově orientovaného programování, které se používá v moderních jazycích jako jsou Java, Python nebo R, které pak přispěly k návrhu objektově orientovaného programování.

(Černý, Mařík, Trčka, 2024, 123-126)

1.5.2 Fungování AI

I když se konkrétní detaily liší podle jednotlivých technik AI, hlavním principem je práce s daty. AI systémy se zlepšují a učí díky zpracování velkého množství dat, při kterém rozpoznávají vzorce a vztahy, které by člověk mohl přehlédnout. Tento proces často zahrnuje algoritmy – sady pravidel nebo instrukcí, které řídí analýzu a rozhodování AI. Strojové učení, které je populární podmnožinou AI, využívá algoritmy trénované na označených nebo neoznačených datech k tvorbě predikcí nebo kategorizaci informací. (Russell. 2016)

1.5.3 Typy umělé inteligence

AI může být rozdělena podle různých fází vývoje nebo podle funkcí, které vykonává. Například jsou rozpoznávány čtyři fáze vývoje AI:

1. **Reaktivní stroje:** Omezená AI, která reaguje pouze na různé podněty na základě předem naprogramovaných pravidel a nedokáže se učit z nových dat (např. šachový stroj IBM Deep Blue).
2. **Omezená paměť:** Většina moderní AI spadá do této kategorie, kde se paměť využívá k učení a zlepšování pomocí nových dat, obvykle prostřednictvím umělé neuronové sítě.
3. **Teorie mysli:** Tento typ AI zatím neexistuje, ale výzkum se zaměřuje na možnost vývoje AI, která by dokázala emulovat lidskou mysl a měla by schopnosti rozpoznávat a reagovat na emoce.
4. **Sebevědomá AI:** Tento typ AI je hypotetický a představoval by stroje, které si uvědomují své vlastní existence a mají lidské intelektuální i emocionální schopnosti.

V současnosti všechna umělá inteligence, kterou máme, spadá do kategorie tzv. "úzké" AI, což znamená, že se zaměřuje pouze na omezenou sadu úkolů. Umělá všeobecná inteligence (AGI), tedy stroj, který by dokázal „myslet a jednat“ stejně jako člověk, zatím neexistuje. (Google, 2024)

1.5.4 Treninkové modely umělé inteligence

Když se v souvislosti s umělou inteligencí mluví o "tréninkových datech", co to vlastně znamená? Je důležité si uvědomit, že umělá inteligence s omezenou pamětí se zlepšuje tím, že se trénuje na nových datech. Strojové učení, které je podmnožinou umělé inteligence, používá algoritmy k tomu, aby analyzovalo data a získalo z nich určité výsledky.

V rámci strojového učení se nejčastěji využívají tři hlavní modely učení:

1. **Supervizované učení:** Tento model strojového učení spojuje konkrétní vstupy s výstupy pomocí označených tréninkových dat (tzv. strukturovaných dat). Jednoduše řečeno, abychom naučili algoritmus rozpoznávat obrázky koček, "nakrmíme" ho obrázky, které jsou označeny jako kočky.
2. **Nesupervizované učení:** Tento model se učí vzorce na základě neoznačených dat (tzv. nestruturovaných dat). Na rozdíl od supervizovaného učení není konečný výsledek znám předem. Algoritmus se učí z dat sám a rozděluje je do skupin podle společných vlastností. Nesupervizované učení je například skvělé pro rozpoznávání vzorců a popisné modelování.
3. **Semi-supervizované učení:** Tento smíšený přístup kombinuje supervizované i nesupervizované učení, přičemž pouze část dat je označená. Konečný výsledek je znám, ale algoritmus musí zjistit, jak data uspořádat a strukturovat, aby dosáhl požadovaného výsledku.

4. **Reinforcement learning:** Tento model lze stručně popsat jako "učení se praxí". Agent se učí vykonávat daný úkol metodou pokus-omyl (tzv. zpětnovazebná smyčka), dokud jeho výkon nedosáhne požadované úrovně. Pokud agent úkol splní dobře, dostává pozitivní zpětnou vazbu, a pokud špatně, zpětná vazba je negativní. Příkladem může být trénink robotické ruky, aby zvedla míč. (Google, 2024)

1.6 Umělá inteligence v Supply Chainu

Integrace umělé inteligence (AI) do dodavatelského řetězce přináší významné zlepšení v plánování, výrobě, řízení a optimalizaci logistických aktivit. AI umožňuje zpracovávat rozsáhlé objemy dat, předpovídat trendy a provádět složité úkoly v reálném čase, což vede k lepšímu rozhodování a zvýšení provozní efektivity.

(IBM, 2024)

Dle studií až 40% organizací investuje do umělé inteligence. (EY,2024)

Přidaná hodnota v AI v supply chain planningu

Demand forecasting – umělá inteligence se dnes často využívá pro analýzu rozsáhlých historických dat o prodejkách, trendech na trhu a dalších faktorech, které ovlivňují poptávku. Díky generativní AI mohou firmy vytvářet modely predikující poptávku v reálném čase. Tyto modely pomáhají optimalizovat úroveň zásob, plánování výroby a logistiku tak, aby efektivně pokryly potřeby zákazníků.

Production planning – AI hraje klíčovou roli při tvorbě plánů výroby a harmonogramů, přičemž zohledňuje proměnlivost zákaznických požadavků, dostupné zdroje, výrobní kapacity a priority jednotlivých objednávek. Generativní AI umožňuje efektivní plánování výrobních procesů, řazení výrobních sekvencí a přidělování zdrojů, čímž minimalizuje úzká místa ve výrobě a zvyšuje celkovou efektivitu.

Risk management – moderní AI technologie dokáží analyzovat historická data, podmínky na trhu, změny počasí či geopolitické události, a tím identifikovat možné rizikové faktory v dodavatelském řetězci. Generativní AI jde ještě dále, protože místo

statických přehledů dokáže na vyžádání vytvářet detailní analýzy rizik, simulace různých scénářů a návrhy strategií pro zmírnění těchto rizik. To umožňuje plánovačům předcházet problémům a efektivněji řídit rizika.

(EY, 2024)

Integrace umělé inteligence do dodavatelského řetězce představuje významnou příležitost pro zvýšení efektivity, snížení nákladů a zlepšení zákaznické zkušenosti. Přestože implementace AI přináší určité výzvy, pečlivé plánování a strategický přístup mohou vést k úspěšnému využití této technologie v logistických procesech.

1.7 Rizika využití umělé inteligence

V předchozích kapitole této diplomové práce jsme se již podrobně zabývali možnostmi využití umělé inteligence v oblasti supply chainu a tím, jak může AI přispět ke zvýšení efektivity procesů, přesnější predikci poptávky, optimalizaci zásob a zlepšení celkové výkonnosti logistických operací. Přestože AI přináší řadu výhod, nelze opomenout potenciální rizika a výzvy, které její implementace přináší.

Proto je klíčové nejen pochopit, jak lze umělou inteligenci efektivně využít, ale také být obeznámen s jejími možnými omezeními a riziky, která mohou ovlivnit spolehlivost, bezpečnost a etické aspekty dodavatelského řetězce. Následující kapitola se zaměřuje právě na tato rizika:

1) Závislost predikce poptávky na datech

Úspěšnost AI v dodavatelských řetězcích je zásadně závislá na kvalitě a přesnosti vstupních dat. Pokud systém pracuje s neaktuálními, nepřesnými nebo neúplnými informacemi, může dojít k chybným výpočtům a následně k nesprávným rozhodnutím. To se může projevit například v situaci, kdy AI podhodnotí skutečnou poptávku, což vede k nedostatku zásob, nebo naopak doporučí zbytečně vysoké nákupy, čímž firmě vzniknou dodatečné náklady. Tento problém je obzvláště závažný v dynamických odvětvích, kde se tržní podmínky rychle mění a kde musí být rozhodnutí založená na aktuálních datech. Aby se předešlo těmto problémům, je nezbytné pravidelně auditovat a ověřovat kvalitu dat, která AI zpracovává. (Zdroj: bluedynamic, 2024)

2) Ochrana citlivých dat a kybernetická bezpečnost

S rostoucím využíváním AI v dodavatelských řetězcích roste také množství citlivých dat, která jsou analyzována a sdílena napříč různými systémy. Tyto informace často zahrnují strategické obchodní údaje, smluvní podmínky s dodavateli, logistické plány nebo finanční analýzy. Pokud by došlo k úniku těchto dat, mohlo by to ohrozit nejen konkurenční výhodu firmy, ale také její celkovou reputaci a spolehlivost v očích partnerů. Kybernetické útoky zaměřené na AI systémy mohou vést k manipulaci s logistickými operacemi, krádeži obchodních tajemství nebo dokonce ke sabotáži dodavatelského řetězce. Firmy proto musí věnovat zvláštní pozornost kybernetické bezpečnosti, pravidelně provádět bezpečnostní audity a zajistit, že jejich AI systémy pracují v souladu s nejnovějšími bezpečnostními standardy. (Zdroj: bito, 2024)

3) Nedostatečná kontrola lidským personálem

Automatizace a umělá inteligence umožňují rychlejší a efektivnější rozhodování, avšak jejich nadměrné spoléhání na AI bez dostatečné kontroly může vést k nekontrolovaným chybám. Pokud například systém pro predikci poptávky doporučí snížení zásob na základě historických dat, aniž by zohlednil aktuální změny na trhu (například sezónní výkyvy nebo krizové situace), může dojít k vážným problémům v dodávkách. Podobné situace mohou nastat i v řízení přepravy – pokud AI rozhodne o optimální trase, ale nezohlední neočekávané dopravní komplikace, může dojít ke zpoždění dodávek. Je proto nezbytné, aby byl každý automatizovaný systém pravidelně monitorován odborníky, kteří zajistí, že AI nepřijímá rozhodnutí izolovaně, ale ve spolupráci s lidskými pracovníky. (Zdroj: bito, 2024)

2 Analýza současného stavu

V této části diplomové práce se nejprve stručně zaměříme na představení společnosti Zebra Technologies, která je předním poskytovatelem technologií a řešení pro efektivní řízení dodavatelských řetězců. Cílem je získat obecné porozumění kontextu, ve kterém společnost působí, a následně se detailněji zaměřit na konkrétní oblast jejího dodavatelského řetězce.

Ve druhé části této kapitoly se budeme zabývat podrobnou analýzou dodavatelského řetězce Zebra Technologies pro region EMEA (Evropa, Blízký východ a Afrika). Tato analýza poskytne vhled do současného stavu a identifikuje klíčové problémy a výzvy, kterým společnost čelí. Na základě získaných dat bude možné navrhnout doporučení pro zlepšení efektivity a optimalizaci procesů v tomto klíčovém regionu.

2.1 Představení společnosti

Zebra Technologies CZ s.r.o. dále jen Zebra Technologies je firma, která patří mezi špičku v poskytování technologických řešení, která pomáhají firmám lépe sledovat a propojovat data, což jim umožňuje optimalizovat své procesy. Specializují se na zařízení jako jsou mobilní počítače, tiskárny, čtečky čárových kódů, RFID systémy, senzory a další moderní technologie pro sledování zásob a dat. Nabízejí hardware, software a služby, které podnikům usnadňují automatizaci, zlepšení provozní efektivity a získávání klíčových informací v reálném čase. Jejich technologie se využívají v oblastech jako zdravotnictví, retail, logistika, výroba a dalších oblastech, kde je potřeba efektivně řídit zásoby, zařízení a pracovní síly.

Zebra Technologies působí ve více než 55 zemích po celém světě. Zebra Technologies má nyní okolo 9750 zaměstnanců a firmá má přes 55 let zkušeností v tvorbě inovací ve výše zmíněných odvětvích. Kromě hardwarových řešení společnost nabízí také softwarové nástroje pro správu zařízení a optimalizaci pracovních toků. (Zebra Technologies, 2024)



Obrázek 6 Logo společnosti (Zdroj: Zebra Technologies, 2024)

2.1.1 Historie společnosti

V roce 1969 založili inženýři Edward L. Kaplan a Gerhard Cless společnost Data Specialties, Inc., která se původně zaměřovala na výrobu vysokorychlostních elektromechanických zařízení pro zpracování dřevných štítků a pásek. Společnost začínala s počátečním kapitálem 1 000 USD.

S rostoucí popularitou čárových kódů uvedla firma v roce 1982 svou první tiskárnu čárových kódů, nazvanou The Zebra. I přes některé nedostatky prototypu byl tento produkt technologicky napřed před konkurencí a získal si oblibu zejména v maloobchodě. Postupně se poptávka po této technologii rozšířila i do zdravotnického a farmaceutického sektoru.

V roce 1986 uvedla Zebra Technologies svůj první model tiskárny založený na termálním tisku, který umožňoval trvanlivý tisk na různé materiály, a tato technologie se brzy stala průmyslovým standardem. V téže době změnila společnost svůj název na Zebra Technologies.

V roce 1993 firma rozšířila své produktové portfolio o tiskárny štítků určené pro průmyslové prostředí, jako jsou továrny a sklady. Tyto nové modely byly levnější díky použití dostupnějších materiálů, například strukturálního plastu, a obsahovaly přibližně o 40 % méně součástí, což zrychlilo výrobu.

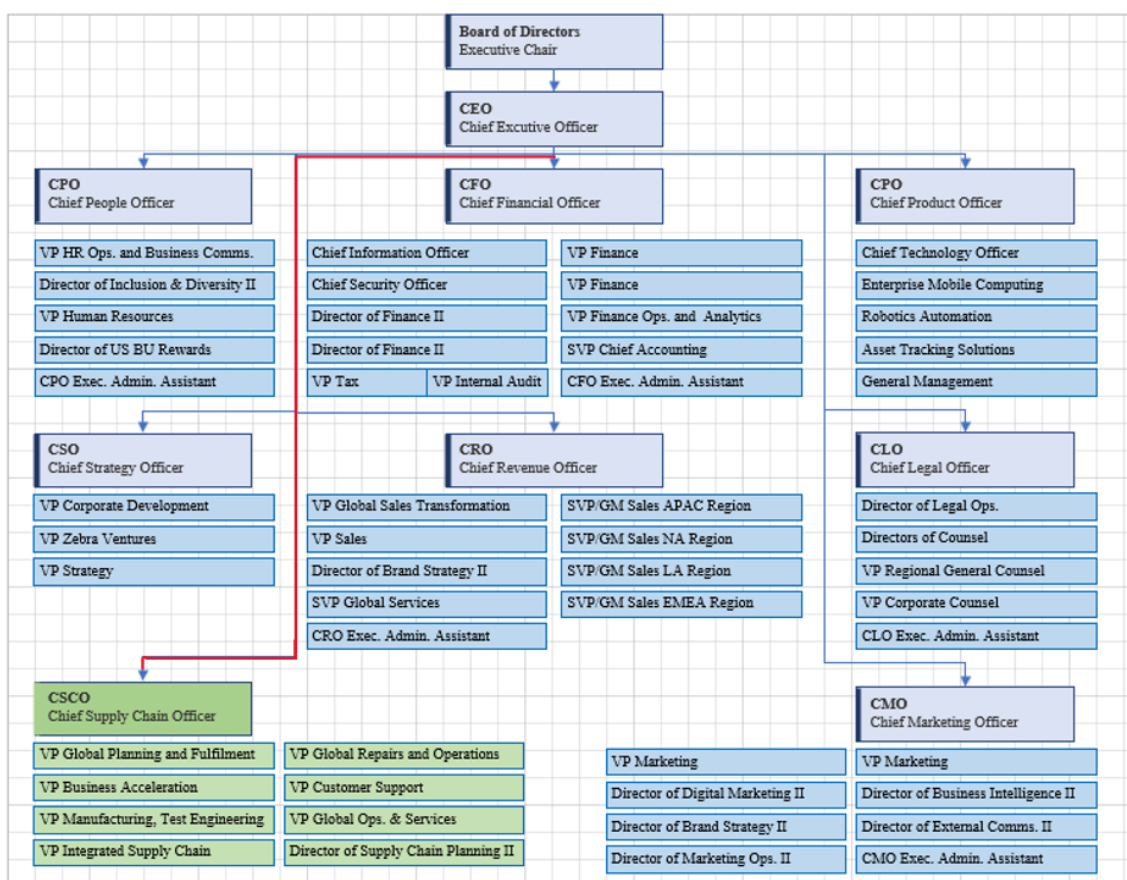
V roce 1998 se Zebra Technologies spojila s Eltron International Inc., což jí umožnilo rozšířit své distribuční trhy a získat větší zákaznickou základnu po celém světě. V 90.

letech společnost rovněž prováděla akvizice menších firem, čímž posilovala své produktové portfolio.

Nejvýznamnější akvizicí byla koupě Motorola Solutions Enterprise Division v roce 2014 za 3,45 miliardy USD. Po této fúzi Zebra Technologies získala přibližně 20 000 obchodních partnerů ve více než 100 zemích a rozšířila svůj tým o dalších 4 500 zaměstnanců. (Zebra Technologies, 2024)

Poslední akvizicí v roce 2024 byla firma Antuit.ai, která poskytuje služby globálním společnostem z žebříčku Fortune 1000 a mění způsob, jakým firmy v oblasti spotřebního zboží a maloobchodu využívají umělou inteligenci k řešení skutečných obchodních výzev. Nabízí řešení, která podporují klíčová rozhodnutí v oblastech, jako je dodavatelský řetězec, merchandising a marketing, a umožňuje špičkovým maloobchodníkům a výrobcům spotřebního zboží projít digitální transformací a dosáhnout významných obchodních výsledků. (Zebra Technologies, 2024)

2.1.2 Struktura společnosti



Obrázek 7: Struktura společnosti Zebra Technologies (Zdroj: interní dokumenty Zebra Technologies)

Organizační struktura společnosti Zebra Technologies je hierarchická a je rozdělena podle klíčových funkcí a strategických oblastí. Na vrcholu struktury stojí CEO (Chief Executive Officer), který odpovídá představenstvu (Board of Directors), a pod ním je několik klíčových řídicích pozic s titulem "Chief".

1. Hlavní výkonné role:

- **CFO (Chief Financial Officer):** Odpovídá za finanční řízení společnosti a dohlíží na oddělení financí, interní audit a účetnictví.
- **CPO (Chief Product Officer):** Zodpovědný za vývoj a řízení produktů, včetně oblastí jako mobilní výpočetní technologie, robotická automatizace a sledovací řešení.
- **CPO (Chief People Officer):** Zodpovídá za lidské zdroje a inkluzi/diverzitu, včetně rozvoje HR strategií.

- **CRO (Chief Revenue Officer):** Odpovídá za řízení příjmů, prodejní transformace a strategii na klíčových regionálních trzích (APAC, NA, LA, EMEA).
- **CSO (Chief Strategy Officer):** Řídí korporátní strategii, rozvoj a investice společnosti Zebra Ventures.
- **CLO (Chief Legal Officer):** Zajišťuje právní záležitosti a dohled nad právními operacemi a poradci společnosti.
- **CMO (Chief Marketing Officer):** Dohlíží na marketingové operace, digitální marketing a externí komunikaci.
- **CSCO (Chief Supply Chain Officer):** Řídí globální dodavatelský řetězec, plánování a výrobní kapacity.

Pro nás v rámci struktury je nejdůležitější linie, která je zbarvena červenou barvou a vede k vedení Supply Chainu v rámci společnosti

2. Podřízené pozice a specializované role:

Každý z hlavních vedoucích má tým složený z viceprezidentů (VP) a ředitelů, kteří dohlízejí na konkrétní oblasti, jako jsou finanční operace, marketing, plánování a plnění, právní operace, podpora zákazníků nebo globální služby.

Viceprezidenti a ředitelé v rámci každého oddělení se zaměřují na konkrétní regiony nebo funkční oblasti, jako je transformace prodeje, globální plánování, servisní služby a další.

2.1.3 Zákazníci

Zebra Technologies má širokou škálu zákazníků napříč různými odvětvími. Její produkty a řešení jsou využívány v oblastech jako je maloobchod a e-commerce, výroba, doprava a logistika, zdravotnictví. Mezi klíčové zákazníky společnosti patří velké firmy jako například firma Amazon, Zalando, Infomil a další.

Zákazníci si vybírají produkty společnosti Zebra Technologies z několika klíčových důvodů. Za prvé, Zebra Technologies nabízí spolehlivá a vysoce výkonná zařízení, která jsou navržena tak, aby splňovala potřeby různých průmyslových odvětví, včetně maloobchodu, výroby, logistiky, u které se dbá na odolnost, kvůli častému manuálnímu používání. Dále se výrobky využívají ve zdravotnictví, ve kterém jsou výrobky odolnější vůči čisticím prostředkům, které se ve zdravotnictví používají. Jejich technologie, jako jsou čárové kódy, RFID, autonomní mobilní roboti a systémy strojového vidění, umožňují firmám efektivněji sledovat a spravovat inventář, automatizovat procesy a zlepšovat pracovní toky. (Zebra Technologies, 2024)

2.1.4 Finační výsledky firmy

Z výkazu zisků (příloha číslo 1.) můžeme vyčíst, že tržby vzrostly z 853 726 tisíc Kč v roce 2022 na 927 596 tisíc Kč v roce 2023. Tento nárůst je klíčovým ukazatelem úspěchu společnosti, protože naznačuje vyšší poptávku po jejích produktech a službách, což pozitivně ovlivňuje celkový finanční výkon.

Dále se zlepšil i provozní výsledek hospodaření a to o téměř dvojnásobek, z 29 177 tisíc Kč na 56 040 tisíc Kč.

Čistý zisk se více než zdvojnásobil, z 30 606 tisíc Kč v roce 2022 na 64 044 tisíc Kč v roce 2023. Tento nárůst je důsledkem růstu tržeb i zlepšení provozní efektivity. Vyšší čistý zisk zvyšuje finanční stabilitu a možnost reinvestice do rozvoje společnosti.



Obrázek 8 Vývoj ceny akcií společnosti Zebra Technologies za posledních 5 let (Zdroj: yahoofinance.com, 2024)

Cena akcií společnosti Zebra Technologies zaznamenala v posledních letech významné výkyvy. Během roku 2021 a na začátku roku 2022 dosáhla svého vrcholu. Poté však následoval výrazný pokles v průběhu roku 2022.

V roce 2023 se cena akcií začala stabilizovat a postupně oživovat, což může naznačovat zlepšení hospodářských výsledků společnosti, obnovení důvěry investorů a úspěšné přizpůsobení se novým podmínkám na trhu. Tento pozitivní trend pokračuje i v roce 2024, kdy cena akcií nadále roste a aktuálně se pohybuje kolem hodnoty 363,58 USD.

2.1.5 Informační systém

Firma Zebra Technologies v rámci svého širokého podnikání používá jak systém Oracle, tak i systémy SAP.

Zebra Technologies se rozhodla pro Oracle kvůli potřebě spolehlivého a škálovatelného technologického partnera, který zvládne podporu prodeje po celém světě – napříč jazyky, časovými pásmy a různými průmyslovými odvětvími. Důležité bylo zajistit přesná a vždy dostupná data, která jsou sdílena mezi aplikacemi.

Zebra Technologies již využívala cloudové služby Oracle Cloud ERP, Oracle Cloud SCM a Oracle Eloqua Marketing Automation. K tomu přidala řešení Oracle Commerce a Oracle CPQ (Configure, Price, Quote), která se osvědčila pro své B2B e-commerce schopnosti a snadnou integraci s dalšími Oracle produkty. Toto spojení umožnilo společnosti spustit online obchodní platformu pro své distributory a partnery, která podporuje upselling a zlepšuje možnosti konfigurace nabídek. (Zdroj: Oracle.com, 2024)



Obrázek 9: Oracle Cloud (Zdroj: Google, 2024)

Zebra Technologies spolupracuje také se SAP na integraci svých zařízení. Konkrétně se tento systém například využívá v Zebra Picking Plus kde je přímo navržené pro SAP Extended Warehouse Management, ve kterém pomáhá organizaci lépe řídit skladové operace. Kromě toho Zebra Technologies nabízí řešení pro tisk štítků přímo z SAP systémů, což usnadňuje integraci jejich tiskáren do prostředí SAP. (Zdroj: Zebra.com, 2024)

V Zebra Technologies se SharePoint využívá jako klíčová platforma pro správu a sdílení dat. Slouží k ukládání reportů a dalších dokumentů, které jsou důležité pro týmovou spolupráci. Díky SharePointu mají zaměstnanci snadný a okamžitý přístup k souborům, což zajišťuje efektivní výměnu informací a podporuje hladký průběh pracovních procesů. Dokumenty, které se sdílí mezi více lidmi, jsou centralizovány a synchronizovány, což minimalizuje riziko verzovacích problémů a zvyšuje produktivitu týmu.

2.2 Supply Chain – Zebra Technologies

V rámci své analýzy se konkrétněji zaměřím na oddělení Supply Chainu, kde současně pracuji na pozici Supply Chain and Repair Intern, což mi poskytuje aspoň základní pohled do tohoto odvětví.

2.2.1 Organizační struktura a role v oddělení

V rámci Supply Chain oddělení v Zebře můžeme identifikovat několik pracovních pozic.

Senior Manager Supply Chain Planning – tato vedoucí pozice je nejvyšší úrovní v rámci supply chain týmu v Brně. Senior manažer zajišťuje řízení a kontrolu ostatních členů týmu, odpovídá za celkový výkon a efektivitu dodavatelského řetězce. Pravidelně reportuje výsledky celého týmu nadřízeným a zajišťuje implementaci strategických cílů.

Supply Chain Planner – je zodpovědný za plánování a koordinaci toku materiálů a informací v rámci dodavatelského řetězce. Zajišťuje, aby byly materiály k dispozici ve správném čase a množství.

Supply Chain Planner Senior – tento seniorní plánovač má obdobné odpovědnosti jako Supply Chain Planner, ale vzhledem k vyššímu počtu let zkušeností a hlubší znalosti procesů mu bývá přiděleno větší množství dílů ke správě a kontrole.

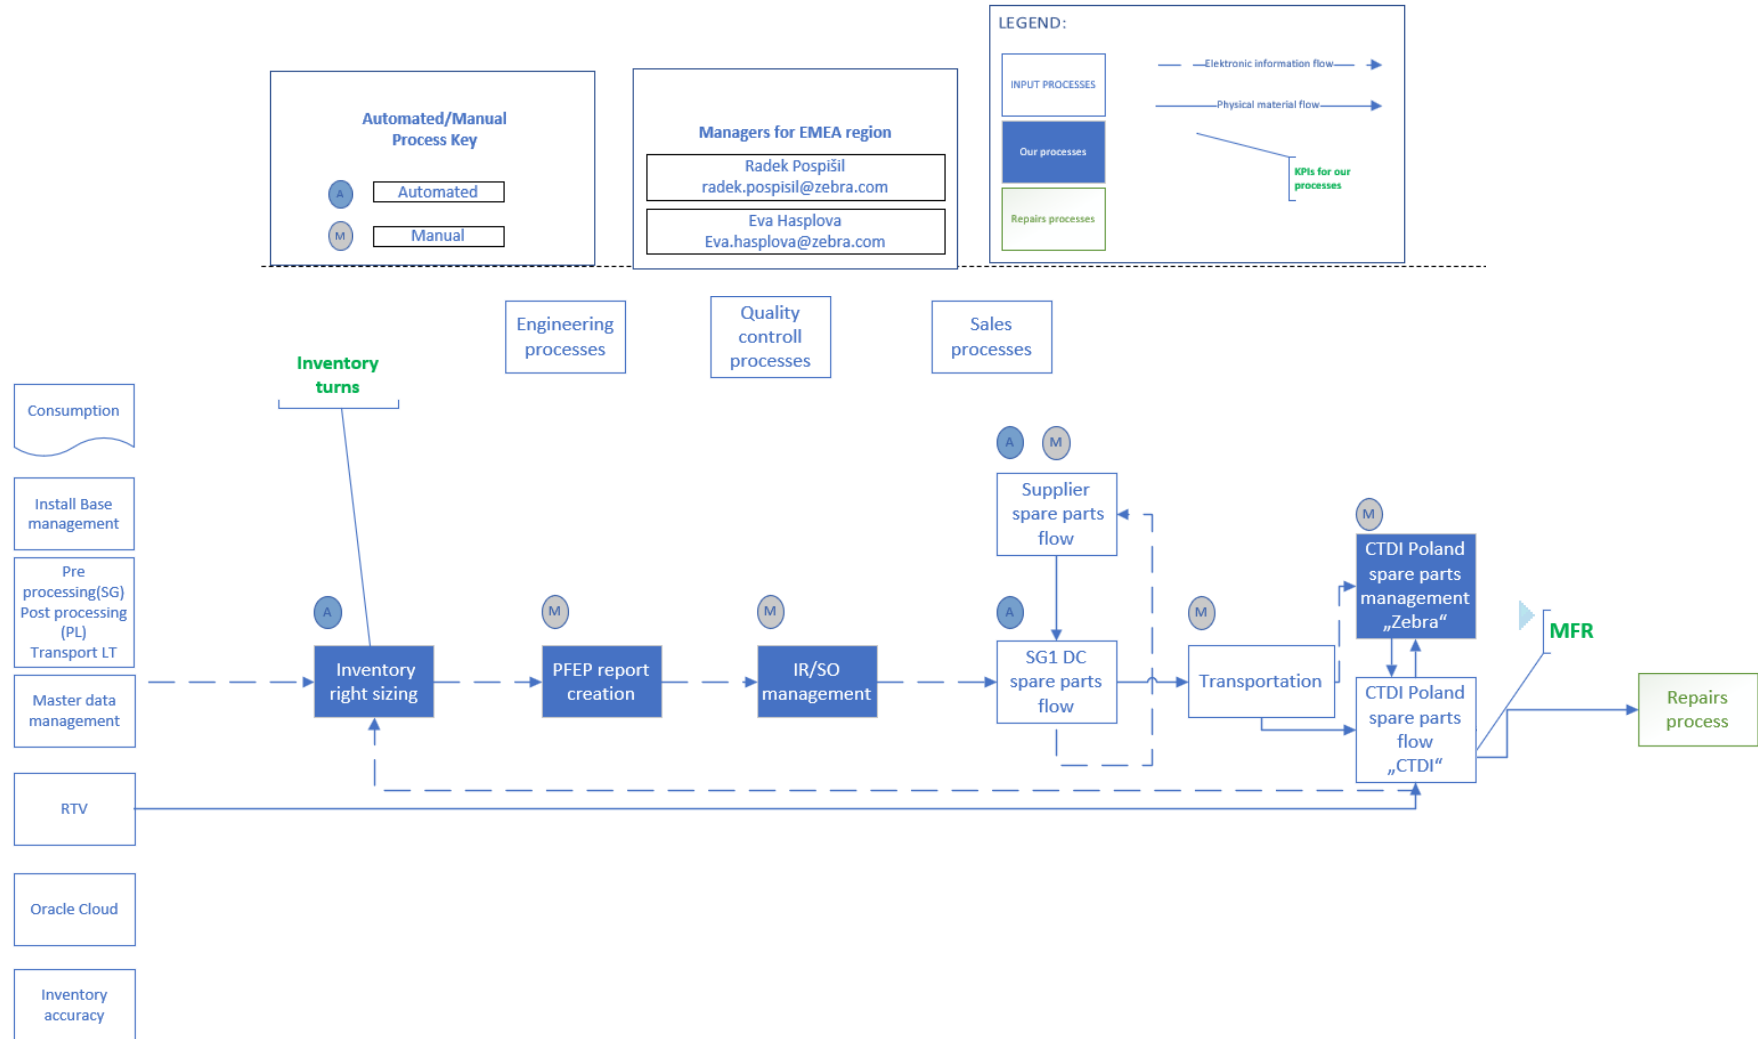
Global Supply Chain and Repair intern – tato pozice je otevřena v létě jako dvouměsíční stáž. Intern pomáhá Senior Managerovi s různými úkoly a zajišťuje podporu při operativních činnostech týmu. Pokud se stážista osvědčí, je zde možnost prodloužení spolupráce formou roční smlouvy.

2.2.2 Hlavní procesy a jejich průběh

Oddělení dodavatelského řetězce (Supply Chain) ve společnosti Zebra Technologies hraje klíčovou roli v zajišťování plynulého toku materiálů a informací napříč celým výrobním a distribučním procesem. S ohledem na potřeby regionu EMEA (Evropa, Blízký východ a Afrika) je supply chain zaměřen na optimalizaci zásob, efektivní řízení zásobovacích procesů, spolupráci s dodavateli a zajištění dostupnosti náhradních dílů pro opravy a údržbu. Tento komplexní systém procesů podporuje Zebra Technologies v dosažení vysoké spokojenosti zákazníků a efektivního využívání zdrojů. Následující popis zahrnuje hlavní procesy, které jsou základem efektivního fungování dodavatelského řetězce v rámci regionu EME

High level Supply Chain process map

Scope: This process describes high level of Supply Chain processes and connections between them for EMEA region



Obrázek 10 High level Supply Chain map (vlastní zpracování)

Na základě procesní mapy výše můžeme identifikovat 4 hlavní procesy pro supply chain:

1. **Inventory Right Sizing:** Tento proces zahrnuje optimalizaci zásob, aby se minimalizovaly náklady a zároveň byly splněny potřeby výroby a zákazníků. Cílem je udržovat zásoby na optimální úrovni a snižovat přebytečné zásoby. Do tohoto procesu vstupují data jako je consumption, install base, RTV data, data z Oracle cloud a další.
2. **PFEP Report Creation :** Neboli Plan For Every Part je report, který je vytvářený v excelu a slouží pro Supply Chain Plannery. V tomto reportu se nacházejí data ohledně jejich spravovaných dílů a všechny informace o nich.
3. **IR/SO Management (Inventory Replenishment / Sales Order):** Řízení doplňování zásob a distribuce je zaměřeno na doplňování skladů a efektivní rozdělení zásob mezi různými distribučními centry a sklady.
4. **CTDI Poland Spare Parts Management:** Tento proces zahrnuje řízení oprav náhradních dílů v opravárenském depu CTDI, se kterým Zebra Technologies spolupracuje. Manažer a plánovači sledují průběh oprav a monitorují počet opravených kusů, se kterými mohou dále počítat pro potřeby distribuce a servisu. Pravidelně se účastní schůzek s týmem CTDI, na kterých je prezentována výkonnost opravárenského centra a dosažené výsledky.

Dále dle procesní mapy můžeme určit vedlejší procesy, které nejsou řízeny supply chainem, ale ovlivňují ho

1. **SG1 DC spare parts flow** – Distribuční centrum (DC) v Singapuru(SG) je místo odkud jsou posílány objednávky do zbytku světa. Úzce komunikuje s dodavateli a podle potřeby u nich objednává potřebné díly.
2. **Supplier spare parts flow** – Jak bylo zmíněno výše dodavatelé spoluprací s distribučním centrem a dle požadavků centrem vyrábí množství potřebných dílů.
3. **Transportation** - z distribučního centra v Singapuru se pak potřebné díly dováží do opravárenského centre v Polsku.

4. **CTDI Poland spare parts flow** – na základě potřebných dovezených dílů začíná jejich oprava.

2.2.3 Používané technologie a systémy

Oracle – firma využívá systémy Oracle pro více procesů, mezi které patří Oracle Cloud, který slouží pro planování zdrojů. Další využití má Oracle v Zebře pro datovou analýzu, kdy umožňuje sběr, analýzu a vizualizaci dat a podporují tedy strategické rozhodování.

Microsoft Exel – se stále používá jako jedna z nejpoužívanějších aplikací pro tvorbu reportů. V těchto reportech se nacházejí data pro plannery a pomáhají jim s jejich plánováním. Hlavní 2 reporty, které si supply chain pravidelně vytváří je Parts Hold report a Plan for Every Part report. Tyto reporty a data které obsahují si více popíšeme v kapitole 2.4. analýza používaných dat.

2.2.4 Efektivita a výkonností ukazatele

Firma využívá několik klíčových vykonnostních ukazatelů (KPIs) k hodnocení efektivity a výkonu dodavatelského řetězce. Mezi hlavní a nejdůležitější dva ukazatele patří:

Material Fill Rate (MFR) – představuje procentuální podíl objednávek, které byly splněny v požadovaném množství a čase z dostupných zásob. Tento ukazatel měří schopnost efektivního řízení zásob. Ve společnosti je MFR nastaven na hodnotu 97 %, což odráží vysokou efektivitu a připouští jen 3% chybovost.

On Time Delivery (OTD) – je ukazatel měřící procento objednávek, které byly zákazníkům doručeny ve stanoveném čase. Tento KPI se zaměřuje na přesnost a rychlost dodávek, což je klíčové pro udržení spokojenosti zákazníků. Společnost Zebra Technologies má nastaveno OTD na 96 %.

Dále můžeme zmínit i vedlejší vykonností ukazatele, které se také sledují ale nemají tak vysokou hodnotu jako výše zmíněné. Mezi tyto ukazatele patří:

Customer Satisfaction (CSAT) – je dalším sledovaným ukazatelem je spokojenost zákazníků. Každý zákazník obdrží e-mail s formulářem, kde může ohodnotit svou zkušenost. Na základě těchto odpovědí je generováno skóre, které odráží celkový pohled zákazníků na výkon společnosti, včetně jejich vnímání OTD (On time delivery – doručení v čase). Tento proces je podobný systému hodnocení, jako například Google recenze. Výsledky jsou monitorovány managementem, který sleduje zpětnou vazbu a identifikuje oblasti pro zlepšení.

Ageing – sleduje dobu, po kterou je zboží v oběhu. Tento ukazatel je důležitý pro optimalizaci procesu oprav a pro předpověď možného nárustu oprav u staršího zboží.

2.3 Identifikace a analýza řízení zásob v Zebra Technologies

Struktura dodavatelského řetězce Zebra Technologies

Zebra Technologies disponuje rozsáhlou logistickou sítí, která zahrnuje nasmlouvané výrobce, distribuční centra (DC), opravná depa a skladištní lokality po celém světě. Tento systém zajišťuje efektivní distribuci náhradních dílů a zařízení k opravným jednotkám a koncovým uživatelům.

Distribuční centra (DC)

Zásobování probíhá prostřednictvím čtyř hlavních distribučních center rozmístěných po celém světě:

- **Kenosha, USA, NA**
- **Herenveen, Nizozemsko, EMEA**
- **Singapur, SG, APAC**
- **FortWorth, USA, NA** – v procesu rušení

Tato DC jsou základními uzly pro distribuci zásob do opravných a skladištních dep.

Opravná a skladištní depa

Opravná depa v rámci Zebra Technologies neslouží pouze k opravám, ale také jako skladištní centra pro distribuci náhradních dílů. V závislosti na regionu se dělí na různě velké jednotky.

Evropa (EMEA)

- **Hlavní opravárenské depo:** Varšava, Polsko

- **Další depo:** Preston, Spojené království (UK)
- **Menší depa:** Skupina pod zkratkou E01 rozmístěná po Evropě
- **Manažer řízení zásob v Evropě:** Radek Pospíšil

Asie a Pacifik (APAC)

- **Hlavní opravárenská depa:** Austrálie a Čína
- **Menší depa:** Pod zkratkou A01
- **Manažerka řízení zásob:** Ong, Siew Hong

Latinská Amerika (LATAM)

- **Hlavní opravárenská depa:** Brazílie, Kolumbie, Mexiko, Argentina
- **Menší depa:** Pod zkratkou U03
- **Manažerka řízení zásob:** Berenice Lopez

Severní Amerika (NA)

- **Hlavní opravárenská depa:**
 - Bentonville
 - Minneapolis
 - Buffalo Grove
 - Memphis
 - Miami
 - Kanada
- **Manažerka řízení zásob:** Koula Vang

2.4 Analýza používaných dat

2.4.1 Parts hold report

Parts Hold report slouží Supply Chain plannerům pro zjištění, že jejich díl je již na holdu, tedy jinými slovy není k dispozici. Je potřeba když planner zjistí, že jeho díl není k dispozici, zajistit aby byl co nejdříve dostupný a kvůli tomuto dílu nestála oprava celých jednotek. Tento report se vytváří každý den v dopoledních hodinách. V rámci tohoto reportu si projdeme nejdůležitější informace, které se v tomto reportu nachazejí:

Business unit AIT/EVM: AIT díly, které se používají do tiskáren, které Zebra Technologies vyrábí a EVM díly se používají do ručních scannerů a dalších přenosných zařízení. Plánování díly EVM a AIT se liší.

Location: Další rozdělení je podle lokace pro kterou planner planuje v rámci Zebry v Brně se planeři starají o tyto země: Velká Británie, Izrael, Maroko, Polsko, Saudská Arábie, Srbsko, JAR, Ukrajina, Spojené arabské emiráty.

Prime: označení názvu daného díly pomocí kodu ve tvaru: P1099875-999.

Hold Gross: Označení pro množsví dílů, které chybí.

ETA: Datum, kdy by mělo dané zboží, které chybí dorazit.

Status: Používají se základní 4 statusy, New – díl je v PH nově a je třeba mu věnovat pozornost, Take action – je potřeba řešit daný díl a podniknout kroky k jeho doručení, In transit – díl je již na cestě do opravarenského depa. Delivered – dané díly byly doručeny

Root cause: Důvod proč daný díl chyběl, mezi nejběžnější důvody patří: zvedla se poptávka u zakazníky na kterou nebyl planner připravený, další používaným důvodem je například globalní nedostatek daného díly, tedy díl nebylo možné objednat, dalším důvodem je první použití, tedy díl nebyl používaný a pak se začal používat.

Action : Kroky, které planner použil pro vyřešení daného problému.

SVC planner code: Každý planner má svůj přidělený SVC kod pod který spadají díly, které má na starost.

2.4.2 Plan for Every Part report (PFEP)

Tento obsáhlý report v excelu slouží také pro Supply Chain plannery, mají zde téměř všechny informace ohledně všech dílů, které mají na starost. Tedy tento report jim slouží

pro kontrolu a pozorování jejich dílu. Vytváří se dvakrát týdně v pondělí a ve čtvrtek. Tento report obsahuje okolo 120 sloupců a 33 000 řádků s data, to Vám může dát přehled jak obsáhlý tento report je. V rámci této analýzy si projdeme pouze ty nejdůležitější informace, které se nejčastěji z tohoto reportu používají. Mezi ně patří:

Business unit AIT/EVM: AIT díly, které se používají do tiskáren, které Zebra Technologies vyrábí a EVM díly se používají do ručních scannerů a dalších přenosných zařízení. Plánování díly EVM a AIT se liší.

Location: další rozdělení je podle lokace pro kterou planner planuje v rámci Zebry v Brně se planeři starají o tyto země: Velká Británie, Izrael, Maroko, Polsko, Saudská Arábie, Srbsko, JAR, Ukrajina, Spojené arabské emiráty

Prime: označení názvu daného dílu pomocí kodu ve tvaru: P1099875-999.

Price unit: cena za jednotku dílu

ABC Rating: rozdělení na základě podílu na zásobách, toto rozdělení ve firmě je v poměru 80% hodnocení A, 15% hodnocení B, 5% hodnocení C

Consumption: nachází se zde spotřeba dílu na měsíce za posledního půl roku

Forecast: předpověď poptávky na jednotlivý díl na měsíc dopředu na půl roku

Lead time: dodací čas, kdy zboží dojde od dodavatele na depo je nastavený u všech jednotek na 14 dní

MIN: minimální počet týdnů spotřeby, které by měly zásoby pokrývat, hodnota MIN (počet týdnů, které minimální zásoba pokrývá) je stanovená podle postupného odhadu, který se ve firmě postupně měnil až se došlo k číslu, které vyhovuje

MAX: maximální počet týdnů spotřeby, které by měly zásoby pokrývat, stejně jako u minimální hodnoty, se zde postupnými úpravi došlu k odhadu maximálního množství týdnů, které by tato zásoba měla pokrývat

QOH: (Quantity on hand): množství zboží, které je připraveno na skladě

In Transit: množství zboží, které je na cestě na sklad

Buyer: nákupční, který objednává zboží u dodavatele

XYZ: v rámci řízení zásob firma nevyužívá analýzy XYZ, která se zabývá volatilitou poptávky po zboží

2.5 Analýza modelů umělé inteligence využitelné pro Supply Chain

V rámci této kapitoly si vytvoříme analýzu 3 nejpoužívanějších a nejpropracovanějších veřejných AI modelů a následně si je porovnáme na datech abychom zjistili, který z nich je nejkompabilnější pro supply chain potřeby.

ChatGPT

je jazykový model, navržený pro generování textu a simulaci přirozené konverzace. Využívá pokročilé algoritmy strojového učení k poskytování odpovědí, vytváření textů a analýze dat.

Tvůrce: OpenAI

Jak funguje: ChatGPT se učí na základě obrovského množství textových dat. Vytváří odpovědi na základě pravděpodobnosti, co by mohlo následovat za předloženým textem.

Hlavní funkce a využití:

- Generování textu: Odpovídá na otázky, vytváří příběhy, vysvětluje pojmy nebo píše eseje.
- Interaktivita: Simuluje lidskou konverzaci, což ho činí užitečným pro zákaznickou podporu nebo osobní asistenci, lze s ním mluvit.

- **Přizpůsobivost:** Adaptabilní pro byznysové záležitosti, kdy vytváří řešení pro jedinečné problémy, kterou daná společnost má (Howtogeek, Kanerika, 2024)

Přístup k internetu: model se může připojit k internetu v reálném čase a čerpat informace z tamo.

Cena: ChatGPT má 3 různé modely k dispozici. Neplacená verze, placená verze a placená verze Business.

Porovnání placené a neplacené verze:

Vlastnosti	Neplacená verze	Placená verze (Personal)	Placená verze (Business)
Model	GPT-3.5	GPT-4 Turbo	GPT-4 Turbo
Rychlost	Pomalejší	Rychlejší	Rychlejší
Procházení webu	Ne	Ano (Browse with Bing)	Ano (Browse with Bing)
Práce s obrázky/PDF	Ne	Ano	Ano
Pokročilé výpočty	Ne	Ano (analýza dat, kódování)	Ano (analýza dat, kódování)
Zprávy za 3 hodiny	40	40 (s výhodou přednostního přístupu)	40 (s výhodou přednostního přístupu)
Znalostní limit	Do ledna 2022	Aktuální informace	Aktuální informace
Cena	Zdarma	\$20/měsíc	\$25/měsíc
Týmové pracoviště (Team workspace)	Ne	Ne	Ano

Obrázek 11 : porovnání placené a neplacené verze CHATGPT (vlastní zpracování, 2024)

Claude

Claude je pokročilý model umělé inteligence. Je navržen tak, aby poskytoval vysoce výkonné a spolehlivé AI řešení pro různé úkoly zahrnující zpracování jazyka, analýzu, kódování a další.

Tvůrce: Anthropic

Jak funguje: Claude se učí na základě rozsáhlých textových dat a využívá pokročilé algoritmy strojového učení k generování odpovědí na základě pravděpodobnostních modelů. Je navržen s důrazem na bezpečnost a spolehlivost, což zajišťuje, že jeho výstupy jsou v souladu s etickými standardy a minimalizují riziko škodlivého chování. (Anthropic, 2024)

Hlavní funkce a využití:

- **Generování textu:** Claude dokáže odpovídat na otázky, vytvářet příběhy, vysvětlovat pojmy a psát eseje.
- **Interaktivita:** Simuluje lidskou konverzaci v textu, zatím ještě neumí používat mluvenou konverzaci.
- **Kódování:** Pomáhá při generování, ladění a vysvětlování kódu, což je užitečné pro vývojáře.

- **Analýza dat:** Schopen analyzovat a interpretovat velké objemy textových dat, což je užitečné pro obchodní analýzy a rozhodování.

Přístup k internetu: Claude nemá nativní schopnost procházet internet v reálném čase. Jeho znalosti jsou omezeny na data, na kterých byl vycvičen, a nemůže přistupovat k aktuálním informacím online.

Cena: Anthropic nabízí různé modely Claude s odlišnými cenovými strukturami. Například model Claude 3.5 Sonnet je k dispozici za \$3 za milion vstupních tokenů a \$15 za milion výstupních tokenů. Ceny se mohou lišit v závislosti na konkrétním modelu a použití. (Anthropic, 2024)

Porovnání placené a neplacené verze:

Vlastnosti	Neplacená verze	Placená verze (Pro)	Placená verze (Team)
Model	Claude	Claude 3	GPT-4 Turbo
Rychlost	Pomalejší	Rychlejší	Rychlejší
Procházení webu	Ne	Ne	Ne
Tvorba obrázků	Ne	Ne	Ne
Pokročilé výpočty	Ano	Ano	Ano
Zprávy	Omezený počet zpráv	Vyšší limit než Free	Vyšší limit než Pro
Znalostní limit	Omezeno množstvím naučených informací	Omezeno množstvím naučených informací	Omezeno množstvím naučených informací
Cena	Zdarma	\$18/měsíc	\$23/měsíc (minimálně 5 uživatelů)
Týmové pracoviště (Team workspace)	Ne	Ne	Ano

Obrázek 12: Porovnání placené a neplacené verze Claude (vlastní zpracování, 2024)

Gemini

Je chatbot s umělou inteligencí. Tento model umí zpracovávat data, včetně textu, obrázků, audia a videa, což umožňuje široké spektrum aplikací v oblasti umělé inteligence.

Tvůrce: Google DeepMind

Jak funguje: Gemini využívá pokročilé algoritmy strojového učení a hlubokých neuronových sítí k analýze a generování obsahu napříč různými modalitami. Jeho trénink zahrnuje rozsáhlé datové sady, což mu umožňuje porozumět a vytvářet obsah v různých formátech. (Google, 2024).

Hlavní funkce a využití:

- **Generování textu:** Gemini dokáže odpovídat na otázky, vytvářet příběhy, vysvětlovat pojmy a psát eseje.

- **Analýza dat:** Schopen analyzovat a interpretovat velké objemy dat, což je užitečné pro obchodní analýzy a rozhodování.
- **Kódování:** Pomáhá při generování, ladění a vysvětlování kódu, což je užitečné pro vývojáře.

Přístup k internetu: Gemini nemá integrovanou schopnost procházet internet v reálném čase. Jeho znalosti jsou omezeny na data, na kterých byl vycvičen, a nemůže přistupovat k aktuálním informacím online.

Cena: Základní verze Gemini je k dispozici zadarmo, ostatní vylepšené verze jsou různé a Google je nabízí na vyžádání. (Google, 2024)

Porovnání placené a neplacené verze:

Vlastnosti	Neplacená verze	Placená verze (Pro)	Placená verze (Enterprise)
Model	Gemini	Gemini 1.5	Gemini 1.5
Rychlost	Pomalejší	Rychlejší	Rychlejší
Procházení webu	Ne	Ne	Ne
Tvorba obrázků	Ano	Ano	Ano
Pokročilé výpočty	Omezené	Ano	Ano
Zprávy	Omezený počet zpráv	Vyšší limit než Free	Vyšší limit než Pro
Znalostní limit	Omezeno množstvím naučených informací	Omezeno množstvím naučených informací	Omezeno množstvím naučených informací
Cena	Zdarma	Cena na vyžádání	Cena na vyžádání
Týmové pracoviště (Team workspace)	Ne	Ne	Ano

Obrázek 13: Porovnání placené a neplacené verze Gemini (Vlastní zpracování, 2024)

zGPT

Interní model v Zebra Technologies postavený na architektuře GPT-4. Model který byl představen v březnu 2023. Model je navržený na stejný princip jako ChatGPT, kdy se snaží uživatelům pomáhat a porozumět širokému množství informací. Nicméně využívá jeho starší verzi, ve které jsou jeho znalosti omezeny do října 2023. Dalším bodem je že nemá přístup k internetu, takže nemůže dohledávat současné informace s jeho využitím.

2.6 Metodologie hodnocení umělé inteligence

V rámci této kapitoly otestujeme výše zmíněné modely umělé inteligence na predikci hodnot zásob na základě historické spotřeby. Každému modelu budou vloženy data spotřeby položek za 6 měsíců nazpět. Model má za úkol na základě historické spotřeby vytvořit předpověď poptávky (forecast) na další měsíc. Když tak udělá budou mu vložena

skutečná data o spotřebě za daný měsíc, aby se mohl podívat na výsledky a případně podle toho upravit forecast na další měsíc. Tímto způsobem získáme data na 3 měsíce dopředu.

U každého modelu se bude hodnotit kolikrát byl nejčastěji nejbližší skutečné spotřebě a na základě výsledku se vybere jeden model, který byl nejúspěšnější. S tímto modelem se pak bude dále pracovat v rámci návrhového řešení.

Tabulka 1: Porovnání modelů umělé inteligence

1. měsíc				2. měsíc				3. měsíc			
ChatGPT	Clade	Gemini	Spotřeba	ChatGPT	Clade	Gemini	Spotřeba	ChatGPT	Clade	Gemini	Spotřeba
828	885	644	1 008	961	992	716	1 636	1291	1700	901	1 452
742	795	594	1 074	915	1025	690	1 546	1280	1620	861	1 373
1366	1410	1255	1 698	1560	1663	1344	2 226	1932	2320	1519	2 714
335	322	299	428	378	408	325	597	502	610	379	661
477	537	467	599	591	583	493	810	713	830	556	1 275
3052	2876	2731	2 380	2578	2485	2670	3 500	3451	3200	2836	4 860
11	11	12	0	8	3	10	21	12	15	12	58
11	17	16	14	16	15	16	21	24	19	17	55
158	166	141	129	172	145	139	210	171	220	154	277
1674	1800	1817	1 154	1269	1096	1684	1 600	815	1580	1667	2 604
1650	1722	1743	1 470	1455	1469	1688	1 201	1208	1250	1591	2 501
1254	1265	1121	1 254	1484	1322	1148	1 686	1709	1720	1255	2 531
10	11	11	9	9	9	11	15	16	14	11	20
1608	1632	1575	1 636	1700	1624	1588	1 732	1695	1750	1616	2 775
199	203	173	287	237	316	196	293	276	302	215	528
213	209	186	227	214	231	192	205	220	210	196	741
11	11	8	17	14	16	10	0	3	5	8	0

(Zdroj: vlastní zpracování, 2025)

Zelené zvýraznění značí, který model byl nejbližší skutečné spotřebě. Žluté označení pak značí stejné hodnoty modelů tedy jinak řečeno remízu. Z celkového počtu 51 predikcí modelů umělé inteligence dopadly výsledky následovně:

ChatGPT: 21

Claude: 18

Gemini: 9

Stejně hodnoty mezi ChatGPT a Claude: 3

Nejlepší predikcí dosahoval tedy model ChatGPT, kdy z celku 51 hodnot byl nejbližší skutečné hodnotě 21krát. Model Claude měl jen o trošku horší výsledky a to 18 nejbližších hodnot z 51. Model Gemini od Googlu dopadl nejhůře s 9 nejbližšími odhady.

Model ChatGPT a Claude pak sdílejí 3 stejné hodnoty, které jsem nejbližše skutečné hodnotě spotřeby.

Shrnutí:

Na základě analýzy budeme dále ze všech veřejně dostupných umělých inteligencí využívat ChatGPT. Tento model byl vybrán z důvodu, že byl nejpřesnější v rámci odhadů spotřeby v naší analýze výše. Dalším důvodem je, že interní verze umělé inteligence zGPT, kterou si vytváří sama firma Zebra Technologies vychází právě z modelu ChatGPT. V rámci zlepšení možností, které umělá inteligence může poskytovat se bude používat placená verze ChatGPT. Díky tomu se otevřou možnosti lepší a širší optimalizace pomocí umělé inteligence.

2.7 Identifikace oblastí aplikace AI v supply chain managementu

V současné době, kdy globální ekonomika zažívá rychlý rozvoj, se řízení dodavatelského řetězce stává klíčovým prvkem pro zajištění hladkého pohybu zboží a služeb od dodavatelů až k zákazníkům. Se zvyšující se složitostí, proměnlivostí a nároky na efektivitu však tradiční přístupy často nejsou schopny dostát současným požadavkům. Právě zde nachází své uplatnění umělá inteligence – inovativní technologie, která zásadním způsobem mění způsob, jakým je dodavatelský řetězec optimalizován. Tato práce se zaměří na strategie využívající umělou inteligenci k optimalizaci dodavatelského řetězce, zhodnotí jejich přínosy a způsoby využití, analyzuje výzvy spojené s implementací a nabídne pohled na budoucí vývoj v této oblasti. (Mirdo, 2024)

Umělá inteligence zahrnuje různé technologie, které se postupně učí z dat a informací, aby mohly rozhodovat a vykonávat úkoly podobné lidské inteligenci. Tyto technologie, jako je strojové učení, zpracování přirozeného jazyka a počítačové vidění, se například využívají v řízení dodavatelského řetězce. Díky nim je možné analyzovat velké objemy dat, hledat v nich vzorce, předpovídat budoucí trendy a zároveň automatizovat procesy pro zlepšení efektivity, přesnosti a flexibility. (Mirdo, 2024)

Možnosti využití umělé inteligence v supply chainu

1. Předpovídání a plánování poptávky

Přesné odhady poptávky jsou klíčovým faktorem úspěchu v řízení dodavatelského řetězce. Algoritmy AI analyzují prodejní data, tržní trendy, počasí i popularitu na sociálních sítích, aby dokázaly přesně předvídat budoucí potřeby. Díky neustálému učení se tyto modely přizpůsobují novým datům a zlepšují svou přesnost.

2. Optimalizace zásob

AI zajišťuje správné množství zásob na správném místě a ve správný čas. Analyzuje vzorce poptávky, dodací lhůty a omezení dodavatelského řetězce, čímž snižuje přebytečné zásoby a minimalizuje riziko výpadků.

3. Viditelnost a transparentnost

Díky nástrojům IoT a RFID senzorům poskytuje AI reálný přehled o pohybu zboží v celém dodavatelském řetězci. To umožňuje rychlá a informovaná rozhodnutí na základě aktuálních dat.

4. Prediktivní údržba

Pomocí senzorů a analýzy historických dat AI předpovídá poruchy zařízení nebo potřebu údržby. To zkracuje prostoje, snižuje náklady na opravy a prodlužuje životnost zařízení.

5. Řízení vztahů s dodavateli

AI analyzuje výkonnost dodavatelů, tržní dynamiku a rizika. Díky těmto datům firmy lépe vyjednávají smlouvy, identifikují spolehlivější partnery a minimalizují rizika spojená s dodavatelským řetězcem.

6. Optimalizace tras a logistiky

AI optimalizuje dopravní trasy na základě analýzy dopravní situace, počasí a dalších faktorů. Díky tomu snižuje náklady, zlepšuje dodací lhůty a minimalizuje ekologickou stopu dopravy.

7. Odhalování podvodů a dodržování předpisů

AI porovnává data z transakcí a sleduje případné odchylky od normálu, aby identifikovala podvodné aktivity. Zároveň kontroluje soulad s předpisy, čímž zvyšuje bezpečnost a důvěryhodnost dodavatelského řetězce.

Výzvy spojené s využitím umělé inteligence v supply chainu

Umělá inteligence nabízí obrovské možnosti, ale její implementace v oblasti řízení dodavatelského řetězce přináší i určité výzvy, mezi tyto výzvy patří:

1. Kvalita a integrace dat

AI závisí na množství dat z různých zdrojů, které musí být nejen kvalitní, ale i konzistentní. Problémy mohou nastat při integraci dat napříč celým dodavatelským řetězcem, kde mohou chybět přesné a sjednocené informace.

2. Škálovatelnost

Úspěšné využití AI vyžaduje robustní infrastrukturu a dostatečný výpočetní výkon, aby zvládla obrovské množství dat a složité procesy. Investice do škálovatelných řešení mohou být finančně i technologicky náročné.

3. Talent a odborné znalosti

Firmy často nemají dostatek odborníků, kteří by uměli vyvíjet a efektivně využívat AI v řízení dodavatelského řetězce. Nedostatek talentu v této oblasti může zpomalit implementaci.

4. Řízení změn

Zavádění AI do stávajících procesů vyžaduje změny v organizaci, což může narazit na odpor zaměstnanců. K úspěšné implementaci je potřeba správné školení, otevřená komunikace a řízení změn, aby zaměstnanci AI přijali jako přínos. (Mirido, 2024)

Budoucnost umělé inteligence v supply chainu

Optimalizace dodavatelských řetězců prostřednictvím umělé inteligence se stává stále důležitější součástí moderních obchodních strategií. Klíčové trendy, které pravděpodobně ovlivní budoucnost dodavatelských řetězců využívajících umělou inteligenci, zahrnují:

1. Konvergence umělé inteligence a IoT

Spojení umělé inteligence a internetu věcí (IoT) umožní pokročilý sběr, monitorování a analýzu dat v reálném čase. Tato integrace povede k přesnější optimalizaci a lepšímu rozhodování.

2. Pokročilá prediktivní analýza

Prediktivní analýza poháněná AI bude stále sofistikovanější, což umožní firmám přesněji předvídat narušení dodavatelského řetězce a včas na ně reagovat.

3. Autonomní provoz dodavatelského řetězce

Technologie, jako jsou autonomní drony a vozidla řízená umělou inteligencí, promění logistiku a dopravu. Tyto inovace sníží závislost na lidských zásazích a zvýší celkovou efektivitu.

4. Udržitelnost a ekologické dodavatelské řetězce

AI bude hrát klíčovou roli při vytváření ekologicky šetrnějších dodavatelských řetězců. Optimalizace zaměřená na snižování uhlíkové stopy a zavádění udržitelných postupů se stane prioritou.

5. Kolaborativní platformy poháněné AI

Integrace AI do kolaborativních platforem umožní efektivní sdílení dat mezi partnery v dodavatelském řetězci. To podpoří lepší koordinaci a synergii, což povede k vyšší výkonnosti celého systému. (Mirido, 2024)

Shrnutí

V rámci této diplomové práce se zaměříme především na využití umělé inteligence v prediktivní analýze poptávky a optimalizaci zásob, které hrají klíčovou roli při efektivním řízení dodavatelského řetězce ve společnosti Zebra Technologies. Hlavním cílem je

vytvořit model, který na základě historických dat a pokročilých algoritmů dokáže přesně předpovědět poptávku a optimálně nastavit skladové zásoby, aby byla zajištěna plynulost dodávek bez nadměrných nákladů na přebytečné zásoby.

2.8 Analýza rizik umělé inteligence

Jak jsme se již dověděli, tak umělá inteligence zefektivňuje supply chain, zlepšuje predikci poptávky a automatizuje procesy. Přesto její implementace přináší rizika, jako je závislost na datech, kybernetické hrozby, chybná rozhodnutí či etické problémy.

Tato kapitola se zaměřuje na klíčová rizika AI v dodavatelských řetězcích, jejich příčiny, důsledky a možnosti prevence.

V rámci vnitřního brainstormingu bylo vytvořeno 8 základních rizik, které využití umělé inteligence v rámci supply chainu představuje.

Tabulka 2: Seznam rizik

Riziko	Kategorie	Příčina	Důsledek
Závislost na kvalitě a přesnosti dat	Provozní riziko	Chybná, špatná nebo nekompletní data	Chybná rozhodnutí, neefektivní řízení zásob
Sdílení citlivých informací firmy	Bezpečnostní rizika	Nedostatečná pozornost, uvědomělost pracovníků při vkládání dat	Ohrožení firemního know-how, únik obchodních tajemství, ztráta důvěry zákazníků a partnerů
Kybernetické útoky na AI systémy	Bezpečnostní rizika	Nedostatečné zabezpečení poskytovatelů AI	Získání dat třetí nechtěnou stranou
Poruchovost a výpadky systému	Provozní rizika	Technické problémy, nesprávná integrace AI	Výpadky systému můžou narušit procesy, které jsou na ně navázány
Nesprávné nebo nepřesné odpovědi	Datové rizika	AI modely generují odpovědi, které nemusí být vždy pravdivá	Chybné rozhodnutí na základě špatných informací
Neschopnost zvládnout	Provozní rizika	AI modely nejsou nyní schopny efektivně reagovat na změny trhu	Narušení dodavatelského řetězce

krizové/náhlé změny trhu			
Právní a etická nejistota	Regulační rizika	Nejasné právní předpisy týkající se využívání AI	Možné právní důsledky, porušení regulačních požadavků
Nedůvěra vedení pro využití AI	Provozní rizika	Nedostatečná důvěra vedení firmy pro využití AI, krátké testovací období	Zpomalení implementace AI, nevyužití plného potenciálu, možnost zaostání za konkurencí

(Zdroj: vlastní zpracování, 2025)

Nyní je k těmto rizikům pro lepší analýzu přiřadit jejich pravděpodobnost výskytu a jejich následný dopad, pokud by se toto riziko opravdu stalo. Vynásobením pravděpodobnosti s jejím dopadem dostaneme celkovou hodnotu riziku.

Tabulka 3: Pravděpodobnost a dopad rizik

Riziko	Pravděpodobnost	Dopad	Hodnota rizika
Závislost na kvalitě a přesnosti dat	3	8	24
Sdílení citlivých informací firmy	3	9	27
Kybernetické útoky na AI systémy	2	9	18
Poruchovost a výpadky systému	7	2	14
Nesprávné nebo nepřesné odpovědi	7	3	24
Neschopnost zvládnout krizové/náhlé změny trhu	4	4	16
Právní a etická nejistota	2	3	6
Nedůvěra vedení pro využití AI	8	2	16

(Zdroj: vlastní zpracování, 2025)

Na základě provedené analýzy rizik spojených s implementací umělé inteligence v dodavatelských řetězcích se jako nejzávažnější ukázala následující tři rizika, tyto rizika

by firma měla brát v úvahu pokud se rozhodne implementovat umělou inteligenci do svých procesů.

1) Sdílení citlivých informací firmy (hodnota rizika: 27)

Toto riziko spadá do kategorie bezpečnostních rizik a jeho hlavní příčinou je nedostatečná pozornost a uvědomělost zaměstnanců při vkládání dat. Pokud nejsou zavedeny dostatečné kontrolní mechanismy a zabezpečení, může dojít k ohrožení firemního know-how, úniku obchodních tajemství a ztrátě důvěry zákazníků či partnerů. Pro minimalizaci tohoto rizika je nutné zajistit přísnou politiku ochrany dat, školení zaměstnanců a implementaci robustních bezpečnostních opatření.

2) Nesprávné nebo nepřesné odpovědi AI (hodnota rizika: 24)

AI modely nejsou vždy schopné generovat 100% přesné odpovědi, což může vést k chybným rozhodnutím na základě nesprávných informací. Toto riziko spadá do kategorie datových rizik a jeho minimalizace vyžaduje nejen kvalitní vstupní data, ale také pravidelnou validaci výstupů AI, kontrolní mechanismy a možnost lidského dohledu nad klíčovými rozhodnutími.

3) Nesprávné nebo nepřesné odpovědi AI (hodnota rizika: 24)

AI modely nejsou vždy schopné generovat 100% přesné odpovědi, což může vést k chybným rozhodnutím na základě nesprávných informací. Toto riziko spadá do kategorie datových rizik a jeho minimalizace vyžaduje nejen kvalitní vstupní data, ale také pravidelnou validaci výstupů AI, kontrolní mechanismy a možnost lidského dohledu nad klíčovými rozhodnutími.

Metodologie hodnocení rizik

Hodnocení rizik umělé inteligence v dodavatelských řetězcích probíhalo na základě expertní konzultace a interní analýzy. Nejprve byla identifikována klíčová rizika spojená s implementací AI, která byla formulována na základě interního brainstormingu s mým nadřízeným a manažerem Supply Chainu, Ing. Radkem Pospíšilem.

Společně jsme každému riziku přiřadili hodnotu pravděpodobnosti výskytu a dopadu v případě jeho realizace. Pravděpodobnost byla určena na škále od 1 do 10, kde vyšší hodnota znamenala častější výskyt daného rizika. Stejná škála byla použita pro dopad,

přičemž vyšší číslo odpovídalo závažnějším následkům pro podnikové procesy. Výsledná hodnota rizika byla vypočítána jako součin pravděpodobnosti a dopadu.

Tento přístup umožnil objektivní zhodnocení jednotlivých hrozeb a pomohl identifikovat nejkritičtější rizika, která vyžadují zvýšenou pozornost při implementaci AI do dodavatelských řetězců.

Shrnutí:

Analýza rizik umělé inteligence v rámci předchozích kapitol sice ukazuje, že její využití v dodavatelských řetězcích přináší výhody, ale také zde můžeme najít významná rizika. Nejzávažnějšími hrozbami jsou sdílení citlivých informací (hodnota rizika: 27), nesprávné odpovědi AI (hodnota rizika: 24) a závislost na kvalitě dat (hodnota rizika: 24). Nedostatečná ochrana dat může vést k úniku firemního know-how, proto je nutné zavést přísná bezpečnostní opatření a školení zaměstnanců. AI modely nejsou vždy přesné, což může vést k chybným rozhodnutím, proto je důležitá validace výstupů a lidský dohled. Kvalita AI rozhodnutí je závislá na vstupních datech, což vyžaduje jejich důkladnou kontrolu a pravidelnou aktualizaci. Pro bezpečné využití AI je klíčové tato rizika minimalizovat pomocí efektivních zabezpečení a kontrolních mechanismů.

2.9 Příklady úspěšných implementací AI v supply chainu

Současná akademická literatura dokumentuje řadu úspěšných nasazení umělé inteligence v dodavatelském řetězci, která vedla ke zlepšení klíčových procesů, jako je predikce poptávky, řízení zásob, logistika či podporované rozhodování. Systematické přehledy potvrzují, že integrace AI významně zvyšuje přesnost prognóz, optimalizuje zásoby a celkově zlepšuje rozhodování v SCM. Níže jsou shrnuty hlavní oblasti aplikace AI v dodavatelském řetězci spolu s konkrétními příklady dosažených přínosů.

Predikce poptávky pomocí AI

Predikce poptávky patří k oblastem SCM, kde se AI úspěšně prosazuje. Tradiční statistické metody prognózování často nedokáží reagovat na rychlé změny trhu, zatímco

algoritmy umělé inteligence (zejména strojového učení a hlubokých neuronových sítí) dosahují vyšší přesnosti předpovědí. Přehledová studie za roky 2017–2021 ukázala, že nasazení AI (např. hlubokých neuronových sítí typu LSTM či klasických umělých neuronových sítí) zpravidla významně zlepšuje přesnost prognóz poptávky oproti konvenčním metodám.

Klíčové je též využití širšího spektra dat – například zahrnutí netradičních ukazatelů (počasí, sentiment ze sociálních sítí apod.) pomáhá AI modelům odhalit skryté vzorce poptávky. Jistá studie z prostředí maloobchodu prokázala, že predikční model využívající strojové učení nad údaji o počasí a sentimentu zákazníků překonal tradiční statistické metody o 42 % v přesnosti předpovědi. Přesnější odhady poptávky pak vedou k celkově pružnějšímu a odolnějšímu dodavatelskému řetězci, neboť snižují výskyt jak nadbytečných zásob, tak vyprodaných položek. (Zdroj: researchgate.net, 2025)

Optimalizace zásob s využitím AI

V oblasti řízení a optimalizace zásob umožňuje AI efektivněji nastavovat úroveň skladových zásob a reagovat na změny poptávky. Pokročilé algoritmy, jako je posilované učení, byly úspěšně použity k optimalizaci rozhodování o doplňování zásob či nastavení bezpečnostních skladových hladin. Nasazením AI lze dosáhnout lepší rovnováhy mezi vysokou dostupností produktu a nízkými skladovými přebytky. Například v automobilovém průmyslu implementace AI pro prognózu poptávky po náhradních dílech vedla ke snížení nadbytečných zásob o 34 % při zachování servisní úrovně nad 98 %. To demonstruje, že chytré predikční modely mohou výrazně omezit vázaný kapitál ve skladu, aniž by došlo ke zhoršení schopnosti plnit požadavky zákazníků. Celkově literatura potvrzuje, že AI přináší do správy zásob dynamičtější rozhodování – systémy dokáží v reálném čase upravovat objednávky a doplňování na základě aktuálních dat o prodeích, trendech či zpožděních v dodávkách. Tím se minimalizuje vznik tzv. bullwhip efektu a zvyšuje odolnost celého dodavatelského řetězce. (Zdroj: seejph, 2025)

AI v logistických procesech

Logistické procesy (zejména doprava a skladování) patří mezi další klíčové oblasti, kde byly implementace AI úspěšné. Umělá inteligence pomáhá optimalizovat trasy přepravy, řídit flotily vozidel, zlepšovat řízení skladů i předcházet zpožděním. Případové studie z

praxe ukazují, že nasazení AI může přinést výrazné zvýšení efektivity a přesnosti v logistice. Například využití počítačového vidění a IoT senzorů ve skladu umožnilo téměř dokonale sledovat pohyb zásob (99,9% přesnost) a snížit chybovost při vychystávání objednávek o 67 %, přičemž průchodnost skladu vzrostla o 45 %. V dopravě zase moderní AI algoritmy pro optimalizaci tras a dynamické plánování nákladek pomohly zkrátit trasy a lépe vytižít vozidla – v jedné rozsáhlé studii u 75 společností vedlo nasazení AI k průměrnému snížení emisí CO₂ o 31 % při zachování požadované úrovně doručení. Podobné technologie využívá i globální logistický lídr DHL, který prostřednictvím AI zefektivňuje plánování rozvozů, real-time sledování zásilek a správu skladových zásob, což zároveň zlepšuje zákaznický servis díky rychlejší a spolehlivější dodávce. Tyto příklady ilustrují, že AI dokáže v logistice automatizovat složité operace, předvídat a řešit problémy (např. přeplánovat dopravu při zácpách či výpadcích) a celkově nastavit nový standard efektivity v dodavatelském řetězci. (researchgate.net, 2025)

Shrnutí:

Implementace umělé inteligence v dodavatelských řetězcích na základě výše zmíněných vědeckých publikací prokazatelně zlepšuje klíčové procesy, jako je predikce poptávky, řízení zásob a logistika. AI umožňuje přesnější prognózy, efektivnější správu zásob a optimalizaci přepravy.

V oblasti predikce poptávky AI překonává tradiční metody díky využití pokročilých algoritmů, které dokáží zpracovat širší spektrum dat, včetně počasí či sentimentu zákazníků. Například v maloobchodě dosáhly predikční modely založené na AI o 42 % vyšší přesnosti než konvenční přístupy.

Řízení zásob se díky AI stává dynamičtější – modely posilovaného učení optimalizují úroveň skladových zásob a snižují nadbytečné zásoby, přičemž udržují vysokou dostupnost produktů. V automobilovém průmyslu vedlo nasazení AI ke snížení přebytečných zásob o 34 % při zachování 98% servisní úrovně.

V logistice AI zefektivňuje plánování tras, řízení skladů a sledování zásilek. Automatizované systémy s využitím počítačového vidění dosahují 99,9% přesnosti při sledování zásob a výrazně zlepšují efektivitu skladových operací. Například nasazení AI ve flotilovém managementu vedlo ke snížení emisí, CO₂ o 31 % díky optimalizaci tras a lepšímu vytižení vozidel.

3 Vlastní návrhy řešení

Při tvorbě návrhových řešení bude klíčovým východiskem analytická část, která poskytla cenné poznatky o současném stavu plánování zásob. Díky této analýze bylo možné identifikovat určité nedostatky a slabá místa v dosavadním přístupu k řízení zásob. Zároveň analýza odhalila možné využití umělé inteligence, které dosud nebyly v tomto procesu implementovány, a přitom by mohly výrazně přispět ke zlepšení přesnosti predikcí a automatizaci klíčových operací.

Zajímavým aspektem je, že umělá inteligence se v rámci řešení těchto problémů stala jakýmsi osobním konzultantem v oblasti řízení zásob, který pomáhá identifikovat příčiny nesrovnalostí a navrhopvat adekvátní kroky ke zlepšení.

Tato kapitola se proto zaměřuje na konkrétní návrhy řešení, která vycházejí z identifikovaných problémů a příležitostí. Cílem bylo optimalizovat množství zásob pomocí nového nastavení minima a maxima a k nim vytvoření nové bezpečnostní zásoby, která pokryje volatilitu poptávky. Dalším úkolem bude zjistit, jestli je umělá inteligence schopná podobné ne-li lepší prediktivní analýzy než softwary, za které platí Zebra Technologies velké množství finančních prostředků. A posledním bodem budou možnosti, jak využívat umělou inteligenci jako konzultanta pro řízení zásob, za kterého by se jinak platilo obrovské množství peněz. Návrhy budou formulovány s ohledem na praktickou realizovatelnost v prostředí společnosti Zebra Technologies a jejich přínos pro zlepšení celkového řízení zásob, přičemž klíčovou roli zde bude hrát právě umělá inteligence jako inteligentní asistent v rozhodovacím procesu.

3.1 Prediktivní analýza dat

V analytické části této práce jsme se zaměřili na možnosti využití umělé inteligence k predikci spotřeby materiálu. Cílem bylo zjistit, zda je umělá inteligence, konkrétně model ChatGPT, schopna přesněji predikovat budoucí spotřebu na základě historických dat ve srovnání se systémem Oracle Cloud, který v současnosti využívá společnost Zebra Technologies.

Za tímto účelem byla z interních systémů stažena data o spotřebě dílů TC-21 za posledních deset měsíců. Modelu umělé inteligence byla následně poskytnuta spotřeba za posledních šest měsíců a na základě těchto údajů měl vygenerovat predikci spotřeby na následující měsíc. Tento přístup zajišťuje srovnatelnost s predikcemi systému Oracle Cloud, který rovněž aktualizuje své prognózy měsíčně na základě výsledků z předchozího období.

Tabulka 4: Spotřeba TC21 za 6 měsíců

	1-Jan-24	28-Jan-24	25-Feb-24	31-Mar-24	28-Apr-24	26-May-24
8710-052600-06	414	308	468	401	225	756
8710-052600-07	314	298	378	387	377	575
8710-052600-08	789	831	1,127	978	943	1,512
8710-052600-31	177	205	211	221	168	401
8710-052600-34	408	363	372	405	352	615
8710-052600-48	2,290	4,210	3,220	2,244	2,150	2,834
8710-052600-49	15	27	15	16	9	13
8710-052600-58	31	31	35	18	15	27
8710-052600-70	107	98	121	111	87	174
8710-052601-22	1,180	2,250	3,750	1,901	1,700	2,280
8710-052601-23	2,000	2,200	2,850	1,501	1,502	2,505
8710-052601-25	709	921	1,120	1,004	726	1,231
8710-052601-30	7	11	24	6	10	19
8710-052601-62	1,433	1,703	1,873	1,519	1,265	1,843
8710-052601-63	106	176	198	116	105	219
BTRY-TC2Y-1XMA1-01	77	63	160	136	109	235
BTRY-TC2Y-2XMA1-01	2	9	15	3	7	7

(Zdroj: vlastní zpracování, 2025)

Prvotní tabulka spotřeby dílů byla nahrána do modelu ChatGPT, který na jejím základě vytvořil predikci spotřeby pro měsíc červen. Modelu pak byly nahrány skutečné výsledky za daný měsíc, který model predikoval, aby mohl analyzovat svoje odchylky a upravit podle toho predikce na další měsíce. Tímto principem byla i dosažena rovnost oproti systému Oracle Cloud, který taktéž upravuje svoje predikce podle výsledků v minulém měsíci. Tento proces byl opakován v několika cyklech, přičemž každá další predikce zohledňovala zpětnou vazbu z předchozího měsíce. Takto byla postupně vytvořena čtyřměsíční predikce spotřeby pro 17 položek produktové řady TC21.

Výsledné hodnoty predikce jsou uvedeny v tabulce níže. Sloupec „Spotřeba“ reprezentuje skutečnou spotřebu daného materiálu v příslušném měsíci. Sloupec „ChatGPT“ ukazuje predikovanou hodnotu spotřeby generovanou umělou inteligencí, zatímco sloupec „Cloud“ obsahuje predikce poskytnuté systémem Oracle Cloud.

Tento experiment umožnil nejen srovnání přesnosti predikcí mezi umělou inteligencí a stávajícím systémem Oracle Cloud, ale také poskytl cenné poznatky pro budoucí optimalizaci procesů plánování zásob ve společnosti Zebra Technologies.

Tabulka 5: Srovnání mezi realnou spotřebou a odhady Cloudu a ChatGPT

Part Number	30.06.2024			28.7.2024			25.8.2024			29.9.2024		
	Spotřeba	ChatGPT	Cloud	Spotřeba	ChatGPT	Cloud	Spotřeba	ChatGPT	Cloud	Spotřeba	ChatGPT	Cloud
8710-052600-06	610	568	532	830	632	509	1,044	731	487	1,008	887	509
8710-052600-07	555	543	189	630	594	702	1,042	612	549	1,074	827	702
8710-052600-08	1114	1410	1104	1293	1390	1367	1,690	1341	1239	1,698	1516	1367
8710-052601-31	298	332	281	286	285	274	420	291	239	428	356	274
8710-052600-34	317	523	376	456	435	593	657	376	285	599	516	593
8710-052600-48	3800	2433	2810	2315	2636	3013	3,040	2476	2416	2,380	2838	3013
8710-052600-49	12	10	2	11	10	7	9	10	5	0	12	7
8710-052600-58	0	23	23	20	8	21	14	4	17	14	9	21
8710-052600-70	106	118	96	185	153	115	184	169	89	129	174	115
8710-052601-22	1400	2873	1531	2021	2236	2277	1,600	2128	2187	1,154	1864	2277
8710-052601-23	1680	1995	2221	1820	1784	2777	1,450	1732	1982	1,470	1776	2777
8710-052601-25	1052	1143	1098	1035	1197	1200	1,676	1125	943	1,254	1314	1200
8710-052601-30	13	16	13	10	15	14	8	14	23	9	345	14
8710-052601-62	1360	1644	1569	1681	1818	1769	1,783	1750	1388	1,636	1766	1769
8710-052601-63	148	180	163	184	164	217	264	156	224	287	170	217
BTRY-TC2Y-1XMA1-C	209	154	92	179	212	102	250	211	135	227	210	102
BTRY-TC2Y-2XMA1-C	6	8	6	8	7	3	18	8	14	17	13	3

(Zdroj: vlastní zpracování, 2025)

Zelené zvýraznění: model ChatGPT je blíže k realné spotřebě

Červené zvýraznění: model Oracle Cloud je blíže k realné spotřebě

Žluté zvýraznění: oba modely se shodují v hodnotě

3.1.1 Ekonomické zhodnocení

Z ekonomického hlediska se podíváme především na úspěšnost predikce obou modelů, tedy kolikrát byl který model blíže skutečné spotřebě. Z celkového počtu 68 predikcí (4 měsíce x 17 položek) jsou výsledky následující:

ChatGPT: 43 (63,2 %)

Oracle Cloud: 24 (35,3 %)

Stejně hodnoty: 1 (1,5 %)

Na základě těchto výsledků lze konstatovat, že model ChatGPT byl úspěšnější při predikci spotřeby ve srovnání se systémem Oracle Cloud. Umělá inteligence poskytla přesnější odhad spotřeby ve **více než 63 %** případů, zatímco Oracle Cloud dosáhl přesnosti pouze v 35 % případů. V jednom případě byly predikce obou modelů shodné.

Tyto výsledky naznačují, že využití umělé inteligence může přinést významná vylepšení v oblasti plánování zásob, což by mohlo vést ke snížení přebytečných zásob a efektivnějšímu řízení skladových operací. Dále by bylo vhodné provést hlubší analýzu faktorů, které vedly k nepřesným predikcím, a případně optimalizovat vstupní data a algoritmy používané modelem ChatGPT pro ještě lepší výsledky.

Shrnutí:

Výsledky analýzy ukazují, že model ChatGPT dosahuje vyšší přesnosti v predikci spotřeby oproti stávajícímu systému Oracle Cloud. Nicméně je nutné vzít v úvahu, že zatímco model ChatGPT byl testován na 17 položkách, společnost Zebra Technologies spravuje tisíce položek, což představuje zásadní překážku pro praktické využití této technologie v takovém měřítku.

ChatGPT v současné podobě není schopen efektivně zpracovat tak velké množství dat v rámci automatizovaného procesu. Proto by bylo vhodné provést další analýzu zaměřenou na identifikaci faktorů, díky kterým ChatGPT dosahoval přesnějších predikcí. Tato analýza by mohla pomoci optimalizovat současné predikční modely a případně zkombinovat výhody obou systémů pro dosažení lepších výsledků v širším měřítku.

3.2 Optimalizace zásobových hodnot

Cílem této kapitoly je navrhnout nový model stanovení zásobových hodnot, který zahrnuje bezpečnostní zásobu a zohledňuje volatilitu poptávky prostřednictvím XYZ analýzy. Na základě historických dat a prediktivní analytiky jsou přepočítány nové hodnoty MIN a MAX, které umožní snížení vázaného kapitálu ve skladech.

Metodologický rámec

Optimalizace zásobových hodnot byla prováděna na základě analytického přístupu využívajícího historická data, statistické metody a principy řízení zásob. Konkrétně byla metodologie postavena na následujících krocích:

- 1) Identifikace současného stavu
- 2) Výběr analytických metod
- 3) Výpočet nových minimálních a maximálních hodnot
- 4) Testovací implementace na produktové rodině TC21
- 5) Ekonomické zhodnocení a návrh implementace

Na základě analýzy využívaných dat pro plánování zásob bylo zjištěno, že ve firmě Zebra Technologies se plánuje na základě MIN a MAXU. Tedy jednoduše řečeno pokud se zásoby přiblíží minimální hodnotě, tak se objednají do hodnoty maximální. Mezi největší problém tohoto přístupu je nevyužívání žádné pojistné zásoby (safety stocku) pro případ nečekané změny v poptávce. Zároveň hodnoty MIN,MAX byly stanoveny pomocí odhadu, tedy firma postupně upravovala pocitově hodnoty než došla k řešení, které jim funguje.

Toto řešení ovšem nemusí být optimální, ke kterému se firma Zebra Technologies postupně dopracovala. Pokud by hodnoty byly příliš velké tak by firma zbytečně vázala velké množství peněz v zásobách a pokud by hodnoty byly nastavené malé, tak se firma často setkává s výpatky, kdy by nebyla schopná splnit požadavky poptávky.

Zde se tedy nabízí vytvoření nových hodnot MIN a MAX, které budou obohacené o pojistnou zásobu, aby kryly výkavy v poptávce. Zároveň bude vytvořena analýza XYZ, aby Supply Chain planner věděl jaké výkyvy v poptávce jeho položky mají a mohlo to sloužit pro jeho případné poznámky či změny v množství nakupovaných kusů.

Naše nové hodnoty, jejíž tvorbu si postupně projdeme se budou týkat jedné produktové rodiny. Tato rodina bude použita jako testovací soubor, aby se nenarušil chod celého supply chainu v případě nějakého problému. Vybranou rodinnou je rodina TC21, tato rodina obsahuje 93 položek, se kterými budeme dále počítat. Model Zebra TC21 je přenosný terminál ve stylu PDA (osobní digitální asistent), který představuje cenově

dostupné dotykové zařízení vhodné pro firmy všech velikostí. Díky odolnému provedení zajišťuje každodenní spolehlivý provoz. Tento model je navržen především pro práci v interiéru, což dokládá podpora Wi-Fi připojení. K dispozici je také široká škála profesionálního příslušenství, které usnadňuje jeho používání a správu.



Obrázek 14: model TC21 (Zdroj: Zebra Technologies, 2024)

Prvním krokem bude příprava podpůrných dat pro tvorbu nového minima a maxima a pojistné zásoby. Všechny vzorce a hodnoty níže zmíněné nalezneme v příloze číslo 2.

1) Součet minulé spotřeby za 6 měsíců

První podpůrný sloupec bude součet spotřeby za posledních 6 měsíců. Hodnotu 6 měsíců zde používáme k výpočtům z důvodu, že po takto velké období máme dostupné data v PFEP souboru, který jsme již rozebírali a který používají planeři k rozhodování. K tomuto výpočtu použijeme jednoduchý vzorec SUMA a označíme naše data, v našem konkrétním případě data AF10798:AK10798

2) Průměrná měsíční spotřeba

Druhým krokem je výpočet průměrné měsíční spotřeby, kdy pro výpočet podělíme hodnotu získanou v kroku jedna počtem měsíců, v našem případě hodnotou 6.

3) Směrodatná odchylka

Dalším krokem je vytvoření směrodatné odchylky. Směrodatná odchylka nám říká, jak daleko jsou v průměru jednotlivé údaje rozprostřené kolem svého aritmetického průměru.

Tuto odchylku si opět vytvoříme pro odhad poptávky. Pro tuto funkci použijeme vzorec STDEV.P (AF10798:AK10798)

4) Směrodatná odchylka + dodací lhůta

Nyní k směrodatné odchylce je potřeba započítat dodací lhůtu. Dodací lhůta nám říká za jak dlouho od objednání přijde výrobek do opravarenského depa, kde ho máme objednaný. Zebra Technologies má nastavenou dodací lhůtu pro všechny TC21 výrobky nastavenou na 14 dní. Pro náš výpočet potřebujeme brát v úvahu hodnotu za měsíc proto $14/30 = 0,47$. S hodnotou 0,47 budeme dále počítat jako se základní hodnotou pro dodací lhůtu. Pro výpočet tedy použijeme hodnotu zjištěnou v minulém kroce a tu vynasobíme odmocninou z dodací lhůty (0,47). Pro náš případ tedy platí vzorec $=STDEV.P(AF10798:AK10798)*SQRT(0.47)$

5) Koeficient variability

Dalším pomocným výpočtem je koeficient variability, který vyjadřuje relativní význam průměrné odchylky od střední hodnoty, tedy jakou procentuální část průměru tvoří směrodatná odchylka. Pro jeho výpočet využijeme hodnoty získané ze směrodatné odchylky a tu podělíme průměrnou spotřebou. Opět pro náš případ platí $EE10798/ED10798$.

6) XYZ rozdělení

Na základě hodnot vypočtené z koeficientu variability můžeme určit hodnoty pro XYZ. Obecně nám rozdělení podle XYZ říká jak moc položky kolísají tedy jaká je jejich volatilita. Položky X nám říkají že volatilita spotřeby je stabilní, hodnota Y nám říká že spotřeba může někdy sem tam kolísat a Z položky nám říkají že spotřeba kolísá. Pro rozdělení použijeme základní hodnoty pro průmyslovou odvětví. (Zdroj: demandplanning.net) Kdy pro X položky platí že koeficient variability dále jen KV je menší než 0,1 ($KV < 0,1$) pro Y položky je hodnota KV mezi 0,1 a 0,25 ($0.1 \leq KV < 0.25$) a pro Z položky platí, že hodnota je vyšší nebo rovna 0,25 ($KV \geq 0.25$)

7) Propojení ABC a XYZ analýzy

Další podpůrnou sloupec bude propojení hodnotové analýzy produktu ABC s analýzou volatility XYZ. Toto rozdělení pomůže supply chain plannerum při rozhodování ohledně možných úprav ve forecastu. Toto spojení dvou analýz nám rozdělí položky na AX- drahé stabilní položky, AY- drahé mírně kolísavé položky, AZ- drahé kolísavé položky, BX středně drahé stabilní položky, BY- středně drahé mírně kolísavé položky, BZ- středně drahé kolísavé položky, CX – levné stabilní položky, CY levné mírně kolísavé položky a CZ- levné kolísavé položky.

8) Bezpečnostní zásoby (Safety stock)

Nyní se dostáváme k tvorbě jednoho z primárních sloupců pro plánování zásob a to bezpečností zásoby. Ta by nám měla pokrývat právě výchyly ve spotřebě tak, aby zajistila plynulý chod zásob. Pro výpočet bezpečností zásoby využijeme vzorce:

$$\text{Bezpečnostní zásoba} = Z \times \sigma \times L.$$

Vzorec 1: Výpočet bezpečnostní zásoby

Hodnota Z je hodnota Z-skóre pro požadovanou úroveň služby.

Tabulka 6: Servisní úroveň a Z – skóre

Servisní úroveň (%)	Z- skóre(Z)
90%	1.28
95%	1.65
97%	1.88
98%	2.05
99.5%	2.58
99.9%	3.09

(zdroj: demnadplanning.cz, 2025)

Zebra Technologies má nastavenou úroveň služby 97 %. Tomu odpovídá hodnota 1,88. S touto hodnotou budeme dále počítat. Hodnota sigma (σ) je standardní odchylka poptávky, kterou již máme vypočítanou ze kroku 3. Pro náš případ bude platit tedy vzorec $EE10798 * 1.88 * \text{SQRT}(0,47)$.

9) Tvorba nového minima

Pro tvorbu nového minima využijeme vzorce:

$$\text{MIN} = \text{Bezpečnostní zásoba} + (\text{průměrná spotřeba} * L)$$

Vzorec 2: výpočet hodnoty minima pro zásoby

Kdy hodnotu bezpečnostní zásoby můžeme využít z minulého kroku, průměrnou spotřebu máme vypočítanou z kroku 2 a hodnota L nám udává čas dodání, který jsme si stanovili na hodnotu 0,47. Pro náš případ využijeme vzorce: $EJ10798 + (ED10798 * 0.47)$

10) Tvorba nového maxima

Posledním krokem je vytvoření nového maxima, v rámci tohoto kroku využijeme vzorce:

$$\text{MAX} = \text{MIN} + \text{předpověď budoucí poptávky na další měsíc}$$

Vzorec 3: výpočet hodnoty maxima pro zásoby

Zde již máme všechny hodnoty opět vypočteny v předchozích krocích. Takže využijeme vzorce: $EL10798 + AP10798$

3.2.1 Ekonomické zhodnocení

Když již máme vytvořené nové vzorce pro výpočet nové zásoby je potřeba to porovnat oproti zásobě minulé. Je potřeba na začátku upozornit, že z důvody **citlivých dat** na cenu jednotlivých položek ve firmě Zebra Technologies byla jejich cena **vynásobena** číselným **koeficientem**.

Jak již bylo zmíněno výše kalkulace je vytvořena pouze na jednotku TC21, aby v případě využití této optimalizace nebyl narušen celý chod plánování jednotek. Celkový počet jednotek na které jsou nové výpočty vytvořeny je 76.

Níže je kalkulace součtu všech jednotek pro aktuálně nastavené množství firmou Zebra Technologies s porovnáním nových stanovených množství pomocí nami vypočtených vzorců.

Stanovené hodnoty zásob nastavené pro jednotku TC21 firmou Zebra Technologies:

Zebra Technologies MIN: 56 257

Zebra Technologies MAX: 89 808

Nově vypočtené hodnoty pro jednotku TC21:

Nová hodnota MIN: 22682

Nová hodnota MAX: 57 492

Nově vytvořená hodnota pro bezpečnostní zásobu: 12 055

Když porovnáme hodnoty stanovené firmou Zebra Technologies s hodnotou, kterou jsme vypočítali výše dostaneme že jsme došli ke snížení u minima o **59,68%** a u maximální hodnoty je to o **35,97%** menší. Je vidět že jsou zde razantní snížení u obou hodnot. Je však potřeba brát v úvahu bezpečnostní zásobu, kterou jsme vytvořili z hodnoty 0 na 12 055 kusů.

Aby bylo možné lepší zhodnocení podíváme se na rozdíl v ceně zásob. Toto porovnání nám umožní lépe vidět rozdíl protože z nových výpočtů tam již bude započtena bezpečnostní zásoba. Je potřeba znovu zdůraznit, že v rámci zachování citlových dat na cenu jednotlivých položek byla cena všech vynásobena vybraným koeficientem.

Stanovené finanční hodnoty zásob pro jednotku TC21 firmou Zebra Technologies:

Zebra Technologies MIN: 265,173.36\$

Zebra Technologies MAX: 416,628.93\$

Nově vypočtené hodnoty pro jednotku TC21:

Nová hodnota MIN: 126,398.53\$

Nová hodnota MAX: 313,492.12\$

Nově vytvořená finanční hodnota pro bezpečnostní zásobu: 56,979.79\$

Když porovnáme finanční zhodnocení zásob, tak u finanční hodnoty minima jsme klesli o 138,774.83\$, přepočteno na procenta o 52.33%. U hodnoty maxima jsme klesli o hodnotu 103,136.81\$, přepočteno na procenta o 24.76%. Hodnoty bezpečnostní zásoby jsme zvýšili

z hodnoty 0\$ na hodnotu 56,979.79\$. Pokud tedy dáme dohromady finanční hodnotu zásob, jak minima tak maxima, dostaneme se na hodnotu 681,802.29\$. Hodnota námi vypočtené zásoby opovídá hodnotě 496,870.44\$. Je zde tedy vidět ušetření v hodnotě zásob o **184,931.85\$**. Toto množství peněz má podle výpočtu firma v zásobech navíc a mohla by tyto finanční prostředky využít jinak k tvorbě dalšího zisku.

Směrodatná odchylka-Standard deviation of demand (σ)	Směrodatná odchylka (Standard deviation of demand + Lead time σd)	CV(Coefficient of Variation)	XYZ	ABC + XYZ	Safety stock	Zebra Min (forecast)	New Min	Zebra Max (forecast)	New Max	Safety stock price	Zebra MIN price	New Min price	Zebra Max price	New max price	
1.98	1.36	0.5654443	Z	CZ	2.55	6	4	9	7	\$ 439.70	\$ 378.60	\$ 723.26	\$ 1,537.80	\$ 1,240.40	
0.90	0.62	1.077033	Z	CZ	1.16	3	2	5	4	\$ 0.53	\$ 1.49	\$ 0.71	\$ 2.34	\$ 1.63	
2.56	1.76	0.4518321	Z	CZ	3.30	23	6	37	18	\$ 204.66	\$ 1,452.70	\$ 369.84	\$ 2,282.81	\$ 1,114.08	
0.75	0.51	2.236068	Z	CZ	0.96	0	1	1	1	\$ 5.82	\$ 2.96	\$ 6.77	\$ 4.65	\$ 8.46	
0.75	0.51	2.236068	Z	CZ	0.96	0	1	1	1	\$ 6.03	\$ 3.06	\$ 7.02	\$ 4.81	\$ 8.76	
1.11	0.76	1.6583124	Z	CZ	1.42	1	2	2	2	\$ 10.30	\$ 7.06	\$ 12.57	\$ 11.90	\$ 16.59	
				C		2		3			\$ 14.97		\$ 23.53		
2.09	1.43	1.040933	Z	CZ	2.68	5	4	9	7	\$ 10.14	\$ 19.38	\$ 13.69	\$ 30.46	\$ 24.74	
8.10	5.55	1.4288186	Z	CZ	10.44	8	13	13	18	\$ 3.97	\$ 3.15	\$ 4.98	\$ 4.96	\$ 6.78	
				C		6		9			\$ 2.72		\$ 4.28	\$ 1.38	
				C		1		2			\$ 9.98		\$ 15.69	\$ 18.54	
				C		1		2			\$ 14.11		\$ 22.17	\$ 26.20	
0.75	0.51	2.236068	Z	CZ	0.96	0	1	1	1	\$ 12.58		\$ 14.64		\$ 14.64	
463.58	321.93	0.2714597	Z	CZ	605.22	3947	1418	6202	3618	\$ 193.67	\$ 1,262.93	\$ 453.84	\$ 1,984.60	\$ 1,157.84	
412.27	282.64	0.2443792	Y	BÝ	531.36	3115	1324	5191	3324	\$ 170.03	\$ 996.70	\$ 423.76	\$ 1,661.17	\$ 1,063.76	
8.13	5.58	2.1215431	Z	CZ	10.48	6	12	9	15	\$ 1.05	\$ 0.56	\$ 1.23	\$ 0.88	\$ 1.55	
515.89	353.88	0.3352109	Z	CZ	864.91	3245	1388	5099	3388	\$ 3,949.57	\$ 19,272.33	\$ 8,246.15	\$ 30,285.09	\$ 20,126.15	
4.11	2.82	0.329039	Z	CZ	5.30	37	11	58	21	\$ 3.66	\$ 25.68	\$ 7.71	\$ 40.35	\$ 14.50	
4.57	3.13	0.3608239	Z	CZ	5.89	32	12	51	32	\$ 200.05	\$ 1,097.17	\$ 402.22	\$ 1,724.12	\$ 1,081.42	
2.85	1.96	0.3229668	Z	CZ	3.68	26	8	41	20	\$ 129.47	\$ 910.04	\$ 275.65	\$ 1,430.07	\$ 698.17	
444.51	304.74	0.2431908	Y	AY	572.32	2925	1432	5264	3832	\$ 20,544.75	\$ 104,876.71	\$ 51,351.42	\$ 188,778.07	\$ 137,415.42	
121.46	83.27	0.4276325	Z	AZ	156.55	577	290	1039	740	\$ 5,239.77	\$ 19,316.05	\$ 9,707.35	\$ 34,768.89	\$ 24,768.85	
19.43	13.32	0.2944492	Z	CZ	25.05	18	56	28	56	\$ 68.63	\$ 48.69	\$ 153.62	\$ 76.51	\$ 153.62	
255.96	175.41	0.3598938	Z	CZ	323.77	2386	455	3749	1436	\$ 62.44	\$ 596.46	\$ 113.80	\$ 397.30	\$ 358.93	
505.15	346.32	0.3165123	Z	CZ	651.07	2986	1292	4692	3062	\$ 162.77	\$ 746.51	\$ 320.41	\$ 1,173.09	\$ 770.41	
1266.02	867.94	0.7985817	Z	CZ	1631.72	6525	2377	10254	6377	\$ 407.93	\$ 1,631.34	\$ 594.21	\$ 2,563.53	\$ 1,594.21	
1.41	0.97	0.7071068	Z	CZ	1.82	7	3	10	8	\$ 30.31	\$ 109.31	\$ 45.94	\$ 171.77	\$ 129.09	
197.58	135.46	0.6546132	Z	BZ	254.66	634	397	1056	847	\$ 2,643.36	\$ 6,577.73	\$ 4,115.88	\$ 10,962.88	\$ 8,786.88	
7.22	4.95	0.8841706	Z	CZ	9.31	14	13	22	20	\$ 165.38	\$ 251.19	\$ 233.58	\$ 394.73	\$ 360.14	
0.47	0.32	1.4142136	Z	CZ	0.61	0	1	1	1	\$ 10.01	\$ 6.23	\$ 12.59	\$ 9.78	\$ 16.36	
1.70	1.17	0.6373774	Z	CZ	2.19	5	3	8	6	\$ 35.27	\$ 78.02	\$ 55.45	\$ 122.61	\$ 103.75	
0.50	0.34		Z	CZ	0.64	1	1	1	1	\$ 83.61	\$ 73.49	\$ 114.10	\$ 115.49	\$ 158.60	
4.31	2.96	1.7243959	Z	CZ	5.56	2	7	3	8	\$ 191.73	\$ 96.30	\$ 159.59	\$ 60.19	\$ 183.30	
0.37	0.26	2.236068	Z	CZ	0.48	0	1	0	1	\$ 31.40	\$ 17.25	\$ 36.52	\$ 27.10	\$ 46.98	
0.76	0.52	1.5275252	Z	CZ	0.98	2	1	3	2	\$ 62.37	\$ 102.35	\$ 77.26	\$ 160.84	\$ 140.62	
0.37	0.26	2.236068	Z	CZ	0.48	0	1	0	1	\$ 0.86	\$ 0.53	\$ 1.01	\$ 0.83	\$ 1.33	
					Celková suma	12055.19	56257	22682	89808	57492	\$56,379.79	265173.36	\$126,398.53	416628.93	\$319,492.12

Obrázek 15: Hodnoty zásob ve firmě Zebra Technologies (vlastní zpracování, 2025)

Doporučení:

Pro větší bezpečnost bych doporučil jít na postupné snižování zásob s přechodem na bezpečnostní zásobu. Z vypočítané hodnoty ušetřených zásob **184,931.85\$** by se využilo snížení pouze o 25 % tedy 46 232, 96\$. Pokud by toto snížení zásob o zmíněnou hodnotu vedle k pozitivním výsledkům, tedy nevznikaly by zásobovací problémy, postupně by se přešlo na hodnotu 50 %, 75 % a následně až k celé částce. Tímto více konzervativním způsobem snížení zásob zajistíme její větší stabilitu.

Implementace a další směřování:

Zavedení nového nastavení zásob by mělo být realizováno formou řízeného projektu. Doporučuje se vytvořit implementační plán s přidělením zodpovědných osob, časového harmonogramu a pravidelného vyhodnocení výsledků.

V dlouhodobém horizontu lze výsledky práce využít jako základ pro vytvoření systému nastavování zásob. Dále se doporučuje rozšířit analýzu o další parametry (např. sezónnost, velká odchylka ve spotřebě) a integrovat ji do plánovacího systému společnosti.

Shrnutí:

V této kapitole jsme se zaměřili na optimalizaci zásobových hodnot ve společnosti Zebra Technologies. Stávající systém plánování zásob vychází z pevně stanovených minimálních a maximálních hodnot (MIN/MAX), přičemž jejich nastavení bylo v minulosti často založeno na subjektivních odhadech namísto analytických metod. Tento současný přístup může vést k neefektivnímu řízení zásob.

Abychom tento proces zlepšili, implementovali jsme nový model výpočtu zásob, který zahrnuje několik klíčových prvků:

Bezpečnostní zásoba (Safety Stock) – nově zavedená pojistná zásoba pomáhá eliminovat riziko výpadků v dodávkách při nečekaných výkyvech poptávky.

Výpočet optimálních hodnot MIN a MAX – hodnoty byly stanoveny na základě průměrné spotřeby, směrodatné odchylky a dodací lhůty, což zajišťuje dynamičtější a přesnější plánování.

XYZ analýza – klasifikace položek podle volatility spotřeby umožňuje lepší přizpůsobení plánovacích strategií.

Propojení ABC a XYZ analýzy – kombinace hodnotového a volatilního pohledu na zásoby poskytuje detailnější vhled do struktury skladového portfolia, což pomáhá supply chain plannerům s efektivnějším rozhodováním.

Testovací implementace byla provedena na produktové rodině TC21, která zahrnuje 93 položek. Tento výběr umožnil validaci nového modelu bez rizika narušení celkového provozu supply chainu.

Výsledky ukázaly, že nový přístup přináší vyšší efektivitu v plánování zásob a zároveň zajišťuje stabilnější dodávky při zachování finanční efektivity. Zavedení bezpečnostní zásoby umožňuje lépe reagovat na neočekávané výkyvy poptávky, což minimalizuje riziko výpadků. Dále se ukázalo, že analytická podpora v podobě XYZ analýzy pomáhá lépe pochopit chování jednotlivých položek a umožňuje lepší strategické plánování.

3.2.2 Využití umělé inteligence v rámci optimalizace zásobových hodnot

Umělá inteligence ChatGPT se v procesu optimalizace ukázala jako užitečný hlasový logistický konzultant, který mi umožnil efektivně diskutovat různé přístupy které se ve firmě využívají, rychle ověřovat výpočty a testovat různé scénáře. Tento přístup výrazně zrychlil a zpřesnil celý proces rozhodování.

Závěr

Diplomová práce se zaměřila na optimalizaci řízení zásob ve společnosti Zebra Technologies s využitím moderních analytických metod a umělé inteligence. Bylo prokázáno, že současné nastavení minimálních a maximálních zásob není optimální a vede k nadměrnému vázání finančních prostředků ve skladech. Implementací nově vypočítaných hodnot MIN/MAX spolu s bezpečnostní zásobou bylo dosaženo potenciální úspory ve výši přibližně 185 000 USD pouze u jedné produktové řady TC21.

Dále bylo testováno využití umělé inteligence pro predikci poptávky, přičemž model ChatGPT překonal přesnost predikcí systému Oracle Cloud ve více než 63 % případů. Tento výsledek naznačuje, že AI může hrát klíčovou roli v oblasti plánování zásob a přispět k lepšímu rozhodování v dodavatelském řetězci.

ChatGPT ovšem není v současné podobě schopen efektivně zpracovat tak velké množství dat v rámci automatizovaného procesu. Proto by bylo vhodné provést další analýzu zaměřenou na identifikaci faktorů, díky kterým ChatGPT dosahoval přesnějších predikcí. Tato analýza by mohla pomoci optimalizovat současné predikční modely a případně zkombinovat výhody obou systémů pro dosažení lepších výsledků v širším měřítku.

Navržené změny by mohly firmě Zebra Technologies umožnit efektivnější řízení zásob, snížení provozních nákladů a lepší přizpůsobení se dynamickým změnám poptávky. Doporučuje se postupná implementace nového systému zásobování s pravidelným vyhodnocováním jeho efektivity. V případě pozitivních výsledků může být tato metodika rozšířena i na další produktové řady, čímž se otevřou nové možnosti pro zlepšení celkového dodavatelského řetězce.

Seznam obrázků

Obrázek 1: Návrh příkladu dodavatelského řetězce	10
Obrázek 2: EOQ - Model počítá s konstatní poptávkou v průběhu času.....	14
Obrázek 3: Úroveň zásob s pevnou velikostí objednávky	15
Obrázek 4: Lorenzova křivka	18
Obrázek 5: Histogram	25
Obrázek 6: Logo společnosti	33
Obrázek 7: Struktura společnosti Zebra Technologies	35
Obrázek 8: Vývoj ceny akcií společnosti Zebra Technologies za posledních 5 let.....	37
Obrázek 9: High level Supply Chain map	41
Obrázek 10: porovnání placené a neplacené verze CHATGPT	49
Obrázek 11: Porovnání placené a neplacené verze Claude	50
Obrázek 12: Porovnání placené a neplacené verze Gemini.....	51
Obrázek 13: model TC21	68
Obrázek 14: Hodnoty zásob ve firmě Zebra Technologies	73

Seznam zkratek

AI	Artificial Intelligence
EOQ	Economic Order Quantity
JIT	Just In Time
MRP	Material Requirements Planning
ERP	Enterprise Resource Planning
σ	sigma, standardní odchylka poptávky
RFID	Radio-frequency identification
IoT	Internet of Things
KPI	Key Performance Indicators
GPS	General Problem Solver
KV	koeficient variability
Z	Z-score
PDA	Personal digital assistant
L	Lead time

Seznam tabulek

Tabulka 1: Seznam rizik	57
Tabulka 2: Pravděpodobnost a dopad rizik.....	58
Tabulka 3: Spotřeba TC21 za 6 měsíců.....	64
Tabulka 4: Srovnání mezi realnou spotřebou a odhady Cloudu a ChatGPT	65
Tabulka 5: Servisní úroveň a Z – skóre	70

Seznam rovnic

Rovnice 1: Výpočet EOQ	15
------------------------------	----

Seznam příloh

Příloha č. 1 – Výkaz zisků a ztrát společnosti Zebra Technologies

Příloha č. 2 – PFEP report (Plan for Every Part)

Seznam zdrojů

Chopra, S. & Meindl, P., 2016. *Supply Chain Management: Strategy, Planning, and Operation* 6th ed., Pearson Education.

Waters, D., 2003. *Inventory Control and Management* 2nd ed., Wiley.

Lukoszová, X., 2012. *Logistické technologie v dodavatelském řetězci*, Ekopress.

Campírek, V., Rudolf, K. & Šíroky, J., 2009. *Logistické a přepravní technologie* 2nd ed., Pardubice: Institut Jana Pernera: Ekopress.

Cavinato, J. & Kauffman, R., 1999. *The Purchasing Handbook: A Guide for the Purchasing and Supply Professional* 6th ed., New York: McGraw-Hill.

Lambert, D., Stock, J. & Ellram, L., 2005. *Logistika* 2nd ed., CP Books.

Emmett, S., 2008. *Řízení zásob*, Computer Press.

Sixta, J. & Žižka, M., 2009. *Logistika: metody používané pro řešení logistických projektů*, Brno: Computer Press.

Jones, E., 2017. *RFID and Auto-ID in Planning and Logistics: A Practical Guide for Military UID Applications*, CRC Press.

Russell, S., 2016. *Artificial Intelligence: A Modern Approach, Global Edition* 3rd ed., Pearson.

Google, 2024. What is Artificial Intelligence (AI)? *What is Artificial Intelligence (AI)?* Available at: <https://cloud.google.com/learn/what-is-artificial-intelligence?hl=cs> [Accessed November 5, 2024].

Zebra, 2024. Success Stories. *Success Stories*. Available at: <https://www.zebra.com/us/en/resource-library/success-stories.html> [Accessed November 14, 2024].

Petr, P. & Bohumil, Ř., 2005. *Logistika pro 21. století*; Praha Radix.

Gála, L., Pour, J. & Šedivá, Z., 2015. *Podniková informatika* 3rd ed., Grada.

Basl, J. & Blažiček, R., 2012. *Podnikové informační systémy* 3rd ed., Grada.

Sodomka, P. & Klčová, H., 2010. *Informační systémy v podnikové praxi* 2nd ed., Brno Computer Press.

Keřkovský, M. & Valsa, O., 2012. *Moderní přístupy k řízení výroby* 3rd ed., C.H. Beck.

Applied Predictive Analytics: Principles and Techniques for the Professional Data Analyst

Tomek, G. & Vávrová, V., 2014. *Integrované řízení výroby*, Grada Publishing.

Cimorelli, S., 2016. *Kanban for the Supply Chain: Fundamental Practices for Manufacturing Management* 2nd ed., CRC Press.

Černý, D., Mařík, V. & Trčka, M., 2016. *Proč se nebát umělé inteligence? : AI pohledem nejen českých odborníků*, Jota.

Anon., 2024. Antuit.ai: Now Part of Zebra Technologies. *Antuit.ai: Now Part of Zebra Technologies*. Available at: https://connect.zebra.com/antuit_ai_acquisition_na [Accessed January 14, 2025].

Russell, S.J., 2016. *Artificial Intelligence: A Modern Approach* 3rd ed., Pearson Education.

Mirido.cz, 2025. Optimalizace dodavatelského řetězce řízená umělou inteligencí. [online] Available at: <https://www.mirido.cz/optimalizace-dodavateleskeho-retezce-rizena-umelou-inteligenci/> [Accessed 5 April 2025].

Hoffman, C., 2024. What Is ChatGPT and How Does It Work?. [online] How-To Geek. Available at: <https://www.howtogeek.com/871071/what-is-chatgpt/#how-does-chatgpt-work> [Accessed 5 April 2025].

The Sun

Your Everyday AI, 2024. Free ChatGPT vs ChatGPT Plus: What's the Difference?. [online] Available at: <https://www.youreyeverydayai.com/free-chatgpt-vs-chatgpt-plus-whats-the-difference/> [Accessed 2 January 2025].

IBM, 2024. What is AI in supply chain?. [online] Available at: <https://www.ibm.com/think/topics/ai-supply-chain> [Accessed 12 January 2025].

EY, 2024. How generative AI in supply chain can drive value. [online] Available at: https://www.ey.com/en_gl/insights/supply-chain/how-generative-ai-in-supply-chain-can-drive-value [Accessed 24 February 2025].

OpenAI, 2025. ChatGPT. [online] Available at: <https://chat.openai.com/chat> [Accessed 24 February 2025].

Anthropic, 2025. Claude AI. [online] Available at: <https://claude.ai/> [Accessed 24 February 2025].

Google, 2025. Gemini. [online] Available at: <https://gemini.google.com/?hl=cs> [Accessed 24 February 2025].

Kanerika, 2024. ChatGPT vs Gemini vs Claude: Pros, Cons & Best Choice. [online] Available at: <https://kanerika.com/blogs/chatgpt-vs-gemini-vs-claude/> [Accessed 24 February 2025].

Anthropic, 2024. Introduction to Claude. [online] Available at: <https://docs.anthropic.com/en/docs/intro-to-claude> [Accessed 24 February 2025].

Google Cloud, 2024. Gemini Products. [online] Available at: <https://cloud.google.com/products/gemini> [Accessed 24 February 2025].

Kapko, Y., 2018. UPS: Improving Global Supply Chains and Last-Mile Delivery with Machine Learning. [online] Harvard Business School Digital Initiative. Available at: <https://d3.harvard.edu/platform-rctom/submission/ups-improving-global-supply-chains-and-last-mile-delivery-with-machine-learning> [Accessed 24 February 2025].

Sifted, 2024. How Amazon Is Using AI To Become the Fastest Supply Chain in the World. [online] Available at: <https://sifted.com/resources/how-amazon-is-using-ai-to-become-the-fastest-supply-chain-in-the-world> [Accessed 24 February 2025].

Logiscenter, 2024. Zebra TC21 Datenerfassungsgerät. [online] Available at: <https://www.logiscenter.at/zebra-tc21-datenerfassungsgerat> [Accessed 24 February 2025].

Blue Dynamic, 2023. Umělá inteligence v logistice. [online] Available at: <https://bluedynamic.cz/blog/umela-inteligence-v-logistice/> [Accessed 24 February 2025].

BITO, 2023. Možnosti využití umělé inteligence (AI) v logistice. [online] Available at: <https://www.bitto.com/cs-cz/odbornost/artikel/moznosti-vyuziti-umele-inteligence-ai-v-logistice/> [Accessed 24 February 2025].

Kumar, S., 2023. Application of Artificial Intelligence in Logistics 4.0: DHL Case Study Analysis. [online] ResearchGate. Available at: https://www.researchgate.net/publication/385039143_Application_of_Artificial_intelligence_in_Logistics_40_DHL_case_study_analysis [Accessed 5 April 2025].

SEEJPH, 2024. The Impact of AI on Global Supply Chain Management: A Review of Literature. [online] Available at: <https://www.seejph.com/index.php/seejph/article/view/4559/3005> [Accessed 5 April 2025].

Oracle Cloud, 2025, Zebra Technologies accelerates growth with Oracle Cloud [online] Available at: <https://www.oracle.com/customers/zebra-technologies/> [Accessed 5 April 2025].

SEEJPH, 2024. The Impact of Artificial Intelligence (AI) on Supply Chain Decision-Making: A Comprehensive Analysis. [online] Available at: <https://www.seejph.com/index.php/seejph/article/view/4609/3044> [Accessed 5 April 2025].

Demand Planning, 2021. Safety Stock Coverage Tables. [online] Available at: https://demandplanning.net/wp-content/uploads/2021/09/safety_stock_coverage_tables.pdf [Accessed 5 April 2025].