

Univerzita Pardubice
Dopravní fakulta Jana Pernera

BIG DATA v logistice a jejich následné využití

Jan Vrátil

Diplomová práce

2025

Univerzita Pardubice
Dopravní fakulta Jana Pernera
Akademický rok: 2024/2025

ZADÁNÍ DIPLOMOVÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení:	Bc. Jan Vrátil
Osobní číslo:	D23509
Studijní program:	N1041A040008 Technologie a management v dopravě
Specializace:	Dopravní management, marketing a logistika
Téma práce:	Big Data v logistice a jejich následné využití
Zadávací katedra:	Katedra dopravního managementu, marketingu a logistiky

Zásady pro vypracování

Cílem diplomové práce (DP) je analýza Big Dat, návrh modelu a jeho využití pro podporu rozhodovacích procesů v oblasti logistiky ve společnosti Škoda Auto, a.s. Práce vymezuje a popisuje problematiku Big Dat v kontextu logistiky, věnuje se analytickým nástrojům a efektivnímu zpracování dat. Zaměřuje se na tvorbu a analýzu modelu, který pracuje s daty logistických procesů ve výrobním závodě Kvasiny. Optimalizuje vybrané parametry modelu, hodnotí jejich přínos a formuluje doporučení pro vybrané logistické procesy.

Rozsah pracovní zprávy: **50-60 stran**
Rozsah grafických prací: **dle doporučení vedoucí/ho**
Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:
dle pokynů vedoucí/ho práce

Vedoucí diplomové práce: **doc. Ing. Jiří Křupka, Ph.D.**
Katedra dopravního managementu, marketingu
a logistiky

Datum zadání diplomové práce: **31. října 2024**
Termín odevzdání diplomové práce: **7. května 2025**

L.S.

doc. Ing. Ladislav Řoutil, Ph.D.
děkan

Ing. Pavla Lejsková, Ph.D.
vedoucí katedry

V Pardubicích dne 24. dubna 2025

Prohlašuji:

Práci s názvem BIG DATA v logistice a jejich následné využití jsem vypracoval samostatně. Veškeré literární prameny a informace, které jsem v práci využil, jsou uvedeny v seznamu použité literatury.

Byl jsem seznámen s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnicí Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 7. 5. 2025

Bc. Jan Vrátil v. r.

Chtěl bych vyjádřit svou upřímnou vděčnost doc. Ing. Jiřímu Krupkovi, PhD., za jeho neocenitelnou podporu a odborné vedení při psaní této diplomové práce. Jeho cenné rady, trpělivost a ochota sdílet své znalosti mi byly velkou inspirací a pomohly mi překonat mnohé výzvy během celého procesu. Děkuji za jeho vstřícný přístup a neustálou motivaci, která mi umožnila dosáhnout tohoto významného milníku.

ANOTACE

Cílem diplomové práce (DP) je předzpracování a analýza rozsáhlých reálných dat, návrh modelu a jeho využití pro podporu rozhodovacích procesů v oblasti logistiky ve společnosti ŠKODA AUTO, a.s. Práce vymezuje a popisuje problematiku Big Data v kontextu logistiky, věnuje se analytickým nástrojům a efektivnímu zpracování dat. Zaměřuje se na tvorbu modelu, který pracuje s daty logistických procesů ve výrobním závodě Kvasiny. Optimalizuje vybrané parametry modelu, hodnotí jejich přínos a formuluje doporučení pro vybrané logistické procesy. Na základě analýzy rozsáhlých dat byla navržena optimalizace jako přebalení dílů do menších logistických jednotek, sjednocení podobných variant dílů a vyřazení nevyužívaných položek ze sekvence vychystávání.

KLÍČOVÁ SLOVA

analýza, BIG DATA, logistika, model, optimalizace, zpracování dat

TITLE

The utilisation of Big Data in the field of logistics

ANNOTATION

The objective of this thesis is to preprocess and analysis of extensive real data, the design of a model, and the utilisation of this model to support decision-making processes in the field of logistics at ŠKODA AUTO, a.s. The thesis offers a comprehensive definition and description of Big Data in the context of logistics, with a particular emphasis on analytical tools and effective data processing methodologies. The primary objective of this study is to develop a model that can effectively utilise data from logistics processes within the Kvasiny production facility. The model parameters that are selected for optimisation are then evaluated in terms of their contribution, after which recommendations for selected logistics processes are formulated. Following a comprehensive analysis of the available data, a series of optimizations were proposed. These included the repackaging of parts into smaller logistics units, the consolidation of similar part variants, and the elimination of unused items from the picking sequence.

KEYWORDS

analysis, BIG DATA, logistics, model, optimization, data processing

OBSAH

ÚVOD	9
1 TEORETICKÉ ASPEKTY VYUŽITÍ BIG DATA V LOGISTICE.....	11
1.1 Historie Big Data	11
1.2 Definice a charakteristika Big Data	13
1.3 Technologie používané pro Big Data.....	15
1.4 Power BI a jeho využití pro analýzu Big Data.....	18
1.5 Azure Blob Storage a Big Data.....	19
1.6 Využití Big Data v logistice.....	20
1.7 Použití AI pro Big Data.....	22
1.8 Vychystávání.....	24
2 ANALÝZA POSKYTNUTÝCH DAT	28
2.1 Historie a charakteristika společnosti ŠKODA AUTO a. s.....	28
2.2 Layout svařovny v závodě Kvasiny	29
2.3 Odvolávkové systémy ve ŠKODA AUTO a. s.	30
2.3.1 Systém BMA.....	30
2.3.2 Modul SSW.....	31
2.4 Úvod do problematiky sekvenčního vychystávání.....	31
2.5 Charakteristika a zdroj dat	32
2.6 Význam dat pro analýzu logistických procesů.....	33
2.7 Propojení Big Data s Azure Blob Storage.....	33
2.7.1 Seznámení s prostředím Microsoft Azure	34
2.7.2 Nahrání dat do Azure Blob Storage pomocí portálu Azure	36
2.7.3 Propojení Azure Blob Storage s Power BI.....	37
2.7.4 Transformace dat v Power Query.....	39
2.7.5 Zpřístupnění dat pro analýzu v Power BI.....	40
2.7.6 Automatizovaná aktualizace dat v Power BI	41
3 NÁVRH NA OPTIMALIZACI VYBRANÝCH SEKVENCÍ	43
3.1 Význam nízkého procentuálního využití.....	44
3.2 Návrh na optimalizaci sekvence S19B.....	45
3.2.1 Analýza sekvence S19B.....	45
3.2.2 Přebalení dílů do menších logistických jednotek	49

3.3	Návrh na optimalizaci sekvence S39A a S39B.....	50
3.3.1	Balení volantů	50
3.3.2	Analýza sekvence S39A ŠKODA Kodiaq	52
3.3.3	Návrh na optimalizaci sekvence S39A.....	55
3.3.4	Analýza sekvence S39B SEAT Alteca.....	56
3.3.5	Návrh redukce nízkofrekvenčních dílů pro volanty SEAT Alteca S39B.....	57
4	VYHODNOCENÍ PŘÍNOSŮ NAVRŽENÉHO OPATŘENÍ	59
4.1	Zhodnocení návrhu sekvence S19B	59
4.2	Zhodnocení návrhu sekvence S39A.....	60
4.3	Zhodnocení návrhu sekvence S39B	61
	ZÁVĚR	63
	POUŽITÁ LITERATURA.....	64
	SEZNAM TABULEK.....	68
	SEZNAM OBRÁZKŮ	69
	SEZNAM ZKRATEK.....	70

ÚVOD

Současný vývoj v oblasti digitalizace, automatizace a datové analytiky zásadně mění způsob, jakým podniky přistupují k řízení provozních procesů. V logistice, jakožto klíčové součásti výrobního systému, hrají data stále důležitější roli při plánování, vyhodnocování i optimalizaci činností. Množství informací, které firmy každodenně generují, roste takovým způsobem, že tradiční metody zpracování dat přestávají být dostačující. V tomto kontextu získává na významu pojem Big Data, tedy práce s rozsáhlými a různorodými datovými sadami, které umožňují podrobnější pohled na chování procesů a odhalení úzkých míst i nevyužitého potenciálu.

Práce s rozsáhlými sadami dat přináší nové možnosti v oblasti logistického řízení, a to především při sledování pohybu materiálu, řízení zásob, plánování výroby a vyhodnocování efektivity jednotlivých operací. Díky kombinaci kvalitních dat, vhodných analytických nástrojů a technické infrastruktury lze získat ucelený a aktuální přehled o tom, jak jsou zdroje ve firmě využívány a kde lze dosáhnout zlepšení. Tyto přístupy se prosazují především ve firmách s rozsáhlým výrobním a dodavatelským řetězcem, jako je automobilový průmysl.

Cílem této diplomové práce je zhodnotit možnosti využití Big Data v oblasti interní logistiky a na základě analýzy reálných dat poskytnout konkrétní návrhy na zefektivnění procesů ve výrobním závodě společnosti ŠKODA AUTO a.s. v Kvasinách. Práce se zaměřuje na analýzu dat ze sekvenčního vychystávání, což je logistický proces, který zajišťuje plynulé a správně načasované dodávky komponent k montážním linkám. Díky tomu je možné předejít výpadkům, nadměrnému skladování nebo zbytečné manipulaci. Jedná se o proces, který je velmi citlivý na přesnost a organizaci, a proto je vhodným objektem pro optimalizaci prostřednictvím datové analýzy.

První kapitola práce se věnuje teoretickým základům problematiky Big Data a jejich využití v logistice. Definuje klíčové pojmy, shrnuje vývoj datových technologií a představuje nástroje a platformy, které jsou pro práci s velkými datovými objemy běžně využívány včetně cloudových úložišť a vizualizačních nástrojů. Zvláštní pozornost je věnována také konceptu vychystávání materiálu, které v prostředí výroby sehrává klíčovou roli při správném načasování toku komponent mezi skladem a výrobní linkou.

Druhá kapitola se zaměřuje na analýzu reálných dat poskytnutých společností ŠKODA AUTO a.s. Tato data dokumentují procesy vychystávání ve výrobě a umožňují sledovat četnost výskytu jednotlivých dílů. Popsán je také layout svařovny v Kvasinách, což poskytuje prostorový a technologický kontext pro následnou interpretaci výsledků. Důležitou součástí této

kapitoly je přehled použitých technologií, konkrétně využití cloudového úložiště Microsoft Azure Blob Storage a zpracování dat pomocí nástroje Power BI, který umožňuje rychlou a přehlednou vizualizaci zjištěných hodnot.

Třetí kapitola představuje praktickou část práce. Analyzovány jsou konkrétní sekvence vychystávání S19B, S39A a S39B, které byly zvoleny na základě konzultace s odborníkem ze ŠKODA AUTO. V těchto sekvencích byly identifikovány díly s velmi nízkým procentuálním zastoupením ve vychystávání, které výrazně zatěžují skladové hospodářství a procesy řízení zásob. Práce dále přináší návrhy na optimalizaci, jako je přebalení dílů do menších logistických jednotek, sjednocení podobných variant nebo úplné vyřazení nevyužívaných položek z nabídky. Tyto návrhy vycházejí z reálných dat a jsou formulovány tak, aby byly prakticky využitelné v rámci interní logistiky závodu.

Záměrem této diplomové práce není pouze popis aktuálního stavu, ale především navržení konkrétních a realizovatelných zlepšení, která mohou přispět ke zrychlení, zjednodušení a zlevnění logistických procesů v Kvasinách. Práce zároveň ukazuje, jak lze teoretické poznatky v oblasti Big Data aplikovat v praxi a jak může i relativně drobná optimalizace vést ke zlepšení provozní efektivity a vyšší kvalitě řízení ve složitém výrobním prostředí.

1 TEORETICKÉ ASPEKTY VYUŽITÍ BIG DATA V LOGISTICE

Tato kapitola se zaměřuje na teoretický rámec a klíčové koncepty spojené s využitím Big Data v oblasti logistiky. V úvodu je nejprve představen historický vývoj tohoto pojmu, který souvisí s rostoucím objemem digitálních dat od druhé poloviny 20. století a s vývojem technologií, které umožnily jejich efektivní sběr, ukládání a analýzu. Kapitola následně definuje samotný pojem Big Data a věnuje se jeho základním charakteristikám, které jsou v odborné literatuře nejčastěji vyjadřovány pomocí tzv. modelu „5V“ – objem (volume), rychlost (velocity), různorodost (variety), hodnota (value) a pravdivost (veracity).

Dále je pozornost věnována přehledu hlavních technologií, které se v oblasti Big Data používají. Patří mezi ně například distribuované výpočetní systémy (jako Apache Hadoop nebo Spark), moderní databázová řešení typu NoSQL a analytické nástroje umožňující pokročilou práci s daty, včetně Power BI a Microsoft Azure Blob Storage. Popsány jsou i nástroje pro vizualizaci dat, které napomáhají jejich efektivní interpretaci a využití při rozhodování. Kapitola se rovněž zabývá principy, jako jsou prediktivní analytika, automatizace logistických procesů a optimalizace dodavatelského řetězce, které patří mezi hlavní přínosy Big Data v praxi. V této souvislosti jsou rozebrány i možnosti využití umělé inteligence a strojového učení, které umožňují předvídat vývoj poptávky, zefektivnit plánování tras nebo řídit skladové zásoby.

Závěrečná část kapitoly shrnuje hlavní výzvy a přínosy, které Big Data přináší logistickým společnostem. Patří sem zejména zlepšení efektivity operací, přesnější plánování dopravy, optimalizace skladového hospodářství nebo zvýšení transparentnosti v dodavatelských řetězcích. Ke konci se také kapitola věnuje obecnému pohledu na vychystávání a metody, které se s ním spojují. Kapitola tak poskytuje ucelený přehled teoretických základů, na kterých bude dále postavena praktická část práce zaměřená na konkrétní využití Big Data v logistickém prostředí.

1.1 Historie Big Data

Pojem „Big Data“ má své kořeny v druhé polovině 20. století, kdy se začalo rapidně zvyšovat množství digitálních informací. Jak uvádí Cox a Ellsworth (1997), termín "Big Data" se poprvé objevil ve vědeckém výzkumu v 90. letech 20. století, když vědci čelili výzvám zpracování obrovského objemu dat při analýze vědeckých experimentů. Tito autoři se zaměřili na problém vizualizace velkých datových souborů, kdy se ukázalo, že tradiční softwarové

nástroje nejsou schopny efektivně zpracovávat rostoucí velikost datových souborů. Jejich práce byla zaměřena na to, jakým způsobem lze zvládnout extrémně velké datové sady pomocí pokročilých technik správy dat.

Vývoj Big Data úzce souvisí s nárůstem digitalizace a novými výpočetními technologiemi. Již od 60. a 70. let 20. století začaly vládní agentury a vědecké instituce generovat obrovské množství dat, například v rámci vesmírných výzkumů či vojenských projektů. Výrazný posun nastal v 80. letech s rozvojem osobních počítačů a přístupem k digitálnímu zpracování dat v podnicích. Tento trend eskaloval s příchodem internetu v 90. letech, kdy se začalo hromadit neuvěřitelné množství dat z online interakcí, komerčních aplikací a sociálních sítí.

Dle výzkumu Laneyho (2001) se koncept Big Data popisuje prostřednictvím tzv. „tří V“: Volume (objem), Velocity (rychlost) a Variety (různorodost). Laney identifikoval, že s rostoucí digitalizací nejen roste objem dat (Volume), ale také je zapotřebí analyzovat je v reálném čase (Velocity) a zvládat různé typy datových formátů, od strukturovaných až po nestrukturované (Variety). Tento koncept odráží jednu z hlavních výzev moderní doby, kdy podniky musejí nejen zvládnout narůstající množství dat, ale také se vypořádat s jejich různorodostí a rychlostí zpracování.

Historický vývoj Big Data byl také ovlivněn nárůstem výpočetní techniky a internetu. Podle Mayer-Schönbergera a Cukiera (2013) se s nástupem nových technologií v 21. století, jako jsou cloud computing, internet věcí (IoT) a pokročilé algoritmy, stal sběr a analýza dat dostupnější a rychlejší než kdy dříve. IoT zařízení, která generují neustále nová data z různých senzorů a monitorovacích systémů, se stala jedním z hlavních motorů růstu Big Data. Tito autoři zdůrazňují, že Big Data dnes hraje klíčovou roli v oblasti řízení dodavatelských řetězců, kde pomáhá optimalizovat procesy, zlepšovat efektivitu a minimalizovat náklady prostřednictvím analýzy dat v reálném čase.

Jedním z klíčových milníků v historii Big Data je také vývoj distribuovaných systémů. V roce 2005 vyvinuli Doug Cutting a Mike Cafarella open-source platformu Hadoop, která umožňuje efektivní zpracování a analýzu obrovských datových souborů prostřednictvím paralelního zpracování na mnoha počítačích. Podle Whitea (2012) Hadoop představoval revoluci v tom, jak lze zpracovávat velké datové sady, a výrazně snížil náklady na analýzu dat. Tento systém byl navržen tak, aby zvládal nestrukturovaná data z různých zdrojů, což otevřelo nové možnosti pro analýzu dat ve velkém měřítku.

Zikopoulos a Eaton (2011) ve své práci zdůrazňují, že další velký pokrok v oblasti Big Data přinesla rostoucí dostupnost open-source technologií. To umožnilo i menším organizacím


přístup k nástrojům pro analýzu velkých dat, které byly dříve dostupné jen velkým firmám. Tento demokratizační proces vedl k rychlé adopci Big Data nejen v technologickém sektoru, ale i v tradičních odvětvích, jako je logistika, zdravotnictví či bankovníctví. Díky open-source projektům, jako je Hadoop či Spark, se stalo zpracování Big Data levnější a dostupnější pro širokou škálu firem.

V posledních letech vývoj Big Data posouvá technologie, jako jsou umělá inteligence (AI) a strojové učení. Podle Gandomiho a Haidera (2015) tyto technologie umožňují nejen efektivněji analyzovat data, ale také z nich získávat nové poznatky, které mohou mít zásadní dopad na různé průmyslové aplikace. AI a strojové učení jsou schopny zpracovávat obrovské objemy dat rychleji než kdykoli předtím a vytvářet predikce, které mohou být využity pro zlepšení rozhodovacích procesů, optimalizaci výroby a distribuce či předvídání chování zákazníků.

1.2 Definice a charakteristika Big Data

Pojem Big Data představuje revoluci ve způsobu, jakým společnosti a organizace shromažďují, zpracovávají a využívají data. Ačkoli neexistuje univerzální definice, Big Data obecně popisují soubory dat, které jsou tak velké a komplexní, že je nelze efektivně zpracovávat tradičními databázovými nástroji nebo softwarem. Dle Chen et al. (2014) je klíčovou vlastností Big Data to, že jde o takové datové sady, na které je potřeba využít nové technologie a nové přístupy pro jejich ukládání, zpracování a analýzu.

Základní charakteristiky Big Data bývají často vyjadřovány prostřednictvím tzv. „V“ modelu, který poprvé navrhl Laney (2001). Tyto charakteristiky jsou zobrazeny na obrázku 1 a budou dále podrobně vysvětleny.



Obrázek 1 Big Data a jejich 5 V (PASSIONED, 2023)

Původní model od Laneyho popisuje pouze tři hlavní dimenze Big Data, známé jako „tři V“ a to objem, rychlost a různorodost:

- **Objem (Volume)**

Jednou z nejvýraznějších charakteristik Big Data je jeho objem. Objem dat, která jsou generována každý den, exponenciálně roste díky technologickému pokroku, digitalizaci a rozmachu internetu. Podle odhadů IDC (International Data Corporation) bude celkový globální objem Big Data do roku 2025 přesahovat 175 zettabajtů. Takto velký objem dat nelze zpracovávat tradičními metodami, a proto je nutné tato data zpracovávat pomocí nových technologií, jako jsou distribuované databázové systémy - například Hadoop nebo NoSQL databáze, které umožňují paralelní zpracování velkých souborů dat.

- **Rychlost (Velocity)**

Dalším klíčovým rysem Big Data je rychlost, kterou jsou data generována a zpracována. Díky rozvoji technologií, jako je internet věcí (IoT), mobilní zařízení, senzory a sociální sítě, jsou data neustále vytvářena v reálném čase.

Kambatla et al. (2014) uvádí, že tradiční databázové systémy nebyly schopné zvládnout rychlost příchozích dat, což vedlo k vývoji nových technologií, které umožňují zpracovávat data v reálném čase (real-time processing). Příkladem těchto technologií jsou streamovací platformy, jako Apache Kafka nebo Amazon Kinesis.

- **Různorodost (Variety)**

Big Data obsahují různorodé formáty dat, což je také výzva pro tradiční systémy. Zikopoulos a Eaton (2011) definují, že dnes již nejsou data pouze strukturovaná (tabulková, relační data), ale i nestrukturovaná a polostrukturovaná, např. textové soubory, obrázky, zvuky, videa nebo data ze sociálních sítí. Pro zpracování těchto různorodých dat jsou za potřebí nové způsoby ukládání. Například technologie NoSQL databází je určena pro práci a optimalizaci nestrukturovaných dat, zatímco běžné SQL databáze jsou optimalizované pouze pro strukturované informace.

- **Hodnota (Value)**

Ačkoli Laney (2001) původně popsal Big Data prostřednictvím třech základních dimenzí, mnoho autorů, jako jsou Gandomi a Haider (2015), přidávají čtvrtý aspekt – hodnotu. Tento faktor zdůrazňuje, že data sama o sobě nemají smysl, pokud nejsou transformována do hodnotných informací. Aby data přinesla společnosti konkurenční výhodu, musí být správně analyzována a interpretována. Správná analýza dat může zefektivnit výrobu, optimalizovat logistické procesy nebo predikovat chování zákazníků.

- **Pravdivost (Veracity)**

Pátá dimenze Big Data, jak uvádí internetový zdroj Grand Canyon University (2019), se týká pravdivosti neboli kvalita dat. Vzhledem k tomu, že data pocházejí z různých zdrojů a často nejsou ověřená, je důležité věnovat pozornost jejich spolehlivosti a přesnosti.

Nekvalitní nebo nepravdivá data mohou vést k zavádějícím analýzám a nesprávným rozhodnutím, a proto by mělo být klíčové zajištění validních a pravdivých datových sad.

- **Další charakteristiky**

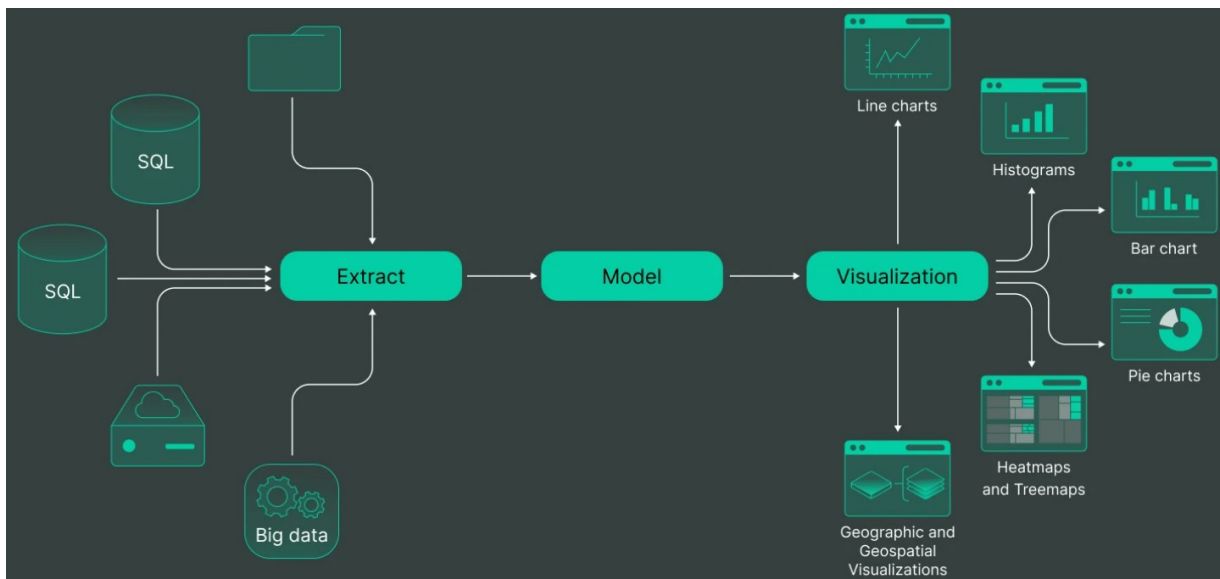
Někteří autoři, jako například Katal, Wazid a Goudar (2013), navrhuji i další „V“ rozšíření pro charakterizaci Big Data, včetně volatility (rychlá změna dat) a vizualizace (schopnost prezentovat data způsobem, který je srozumitelný a užitečný pro koncové uživatele). Jednou z častěji uváděných je také dimenze zranitelnosti (Vulnerability), která souvisí s ochranou dat před kybernetickými útoky, ztrátou nebo únikem.

Big Data jsou nejen definovány svými charakteristickými vlastnostmi, ale také jejich schopností transformovat průmysl a vědu. Jak konstatují Marr a Schmarzo (2016), Big Data se stávají klíčovým faktorem v inovacích a rozhodování v mnoha odvětvích, včetně logistiky, kde můžou přinášet zásadní změny ve způsobu, jakým jsou řízeny dodavatelské řetězce, optimalizovány trasy a monitorovány sklady. Klíčovou výzvou pro organizace zůstává, jak efektivně využít obrovský potenciál dat a transformovat je na konkrétní hodnotu.

1.3 Technologie používané pro Big Data

S exponenciálním nárůstem objemu dat v posledních letech se stává efektivní zpracování a analýza Big Data klíčovým faktorem pro úspěch organizací v mnoha průmyslových odvětvích. Různé technologie byly vyvinuty k tomu, aby umožnily shromažďování, ukládání, analýzu a vizualizaci velkých objemů dat. V této kapitole se zaměříme na hlavní technologie používané pro Big Data, které zahrnují distribuované výpočetní systémy, moderní databázové technologie, analytické nástroje a nástroje pro vizualizaci dat.

Na obrázku 2 je znázorněn proces práce s daty, který začíná extrakcí dat pomocí SQL, standardního jazyka pro práci s databázemi. Následuje fáze modelování, kde jsou data transformována a připravena pro analýzu. Poté jsou data vizualizována, což umožňuje přehledné zobrazení informací a usnadňuje jejich interpretaci. Tento proces ilustruje, jak lze efektivně zpracovat a analyzovat data od jejich získání až po finální vizualizaci.



Obrázek 2 Proces zpracování a vizualizace dat (DOUBLECLOUD, 2023)

- **Distribuované systémy**

Jedním z nejvýznamnějších nástrojů pro zpracování Big Data je Apache Hadoop, který je široce používán pro ukládání a analýzu velkých objemů dat. Podle autora Toma Whitea (2012) umožňuje Hadoop efektivní zpracování dat na mnoha uzlech pomocí paralelního zpracování, což výrazně zvyšuje výkon a škálovatelnost. Hadoop je navržen pro práci s velkým množstvím dat, takže dobře slouží organizacím, které potřebují tato data efektivně zpracovat a analyzovat.

Hlavní komponenty Hadoopu zahrnují Hadoop Distributed File System (HDFS) a MapReduce. HDFS je navržen tak, aby ukládal velké soubory dat distribuovaně na více serverech, čímž zajišťuje redundanci a vysokou dostupnost dat. MapReduce je programovací model, který rozděluje komplexní úlohy na menší, snadno zpracovatelné části, což zajišťuje efektivní zpracování dat. Dle Grolingera et al. (2013) tento model umožňuje zpracovávat jak strukturovaná, tak nestruturovaná data, což je klíčové pro analýzu Big Data.

Dalším důležitým distribuovaným systémem je Apache Spark, který je známý svým rychlým zpracováním dat díky schopnosti provádět výpočty v paměti (in-memory computation). Podle webového zdroje PHOENIXNAP (2020) Spark nabízí vyšší výkon ve srovnání s Hadoopem, zejména při zpracování iterativních úloh, které vyžadují opakované čtení a zápis dat. Spark podporuje různé jazyky, jako jsou Python, Java a R, což usnadňuje integraci do různých pracovních postupů.

- **NoSQL databáze**

Tradiční relační databáze nejsou schopny efektivně zpracovávat různé typy nestrukturovaných a polostrukturovaných dat, což vedlo k rozvoji NoSQL databází. Jak uvádí Grolinger et al. (2013), NoSQL databáze jako MongoDB, Cassandra a Couchbase umožňují ukládat data v různých formátech, jako jsou JSON nebo BSON, a podporují horizontální škálovatelnost. To je klíčové pro organizace, které potřebují rychle reagovat na měnící se požadavky trhu a zákazníků.

NoSQL databáze jsou navrženy tak, aby zvládaly vysoký objem zápisu a čtení dat, což je nezbytné pro aplikace, které vyžadují rychlou odezvu. Tyto databáze také nabízejí flexibilitu ve schématech, což umožňuje organizacím rychle adaptovat své datové modely na nové požadavky. Z tohoto důvodu se staly populárními v oblastech jako je e-commerce, sociální sítě a další aplikace, kde je zapotřebí zpracovávat velké objemy uživatelských dat v reálném čase.

- **Analytické nástroje**

Pro efektivní analýzu Big Data se používají různé analytické nástroje, které umožňují organizacím těžit cenné informace z dat. Jedním z nejpopulárnějších analytických nástrojů je již výše zmíněný Apache Spark, který podporuje zpracování dat v reálném čase a je kompatibilní s Hadoopem. Jak uvádí zdroj PHOENIXNAP (2020), Spark umožňuje rychlé zpracování a analýzu dat díky schopnosti provádět výpočty v paměti. To je nejvíce využitelné pro úlohy, ve kterých je potřeba dělat opakované analýzy jako například strojové učení a statistické modelování.

Neméně důležitým analytickým nástrojem je R a Python, které se staly běžným standardem pro datovou analýzu a vizualizaci. Podle webového zdroje DATAQUEST (2020) tyto programovací jazyky nabízejí širokou škálu knihoven a nástrojů, které usnadňují provádění složitých analýz a vizualizací dat. Programovací jazyk R je obzvlášť silný v oblasti statistických analýz, zatímco Python je oblíbený pro svou univerzálnost a silnou komunitu vývojářů.

- **Nástroje pro vizualizaci dat**

Vizualizace dat hraje klíčovou roli při prezentaci výsledků analýzy a usnadňuje interpretaci složitých datových sad. Nástroje jako Tableau, Power BI a Qlik umožňují uživatelům snadno vytvářet interaktivní grafy a dashboardy, které pomáhají organizacím vizualizovat KPI. Jak uvádí výše zmíněný zdroj DATAQUEST (2020), vizualizace dat přispívá k lepšímu porozumění a interpretaci dat, což je zásadní pro informované rozhodování na úrovni managementu.

Tableau se zaměřuje na intuitivní uživatelské rozhraní a umožňuje uživatelům snadno vytvářet vizualizace bez nutnosti programování. Power BI, nástroj od společnosti Microsoft, se

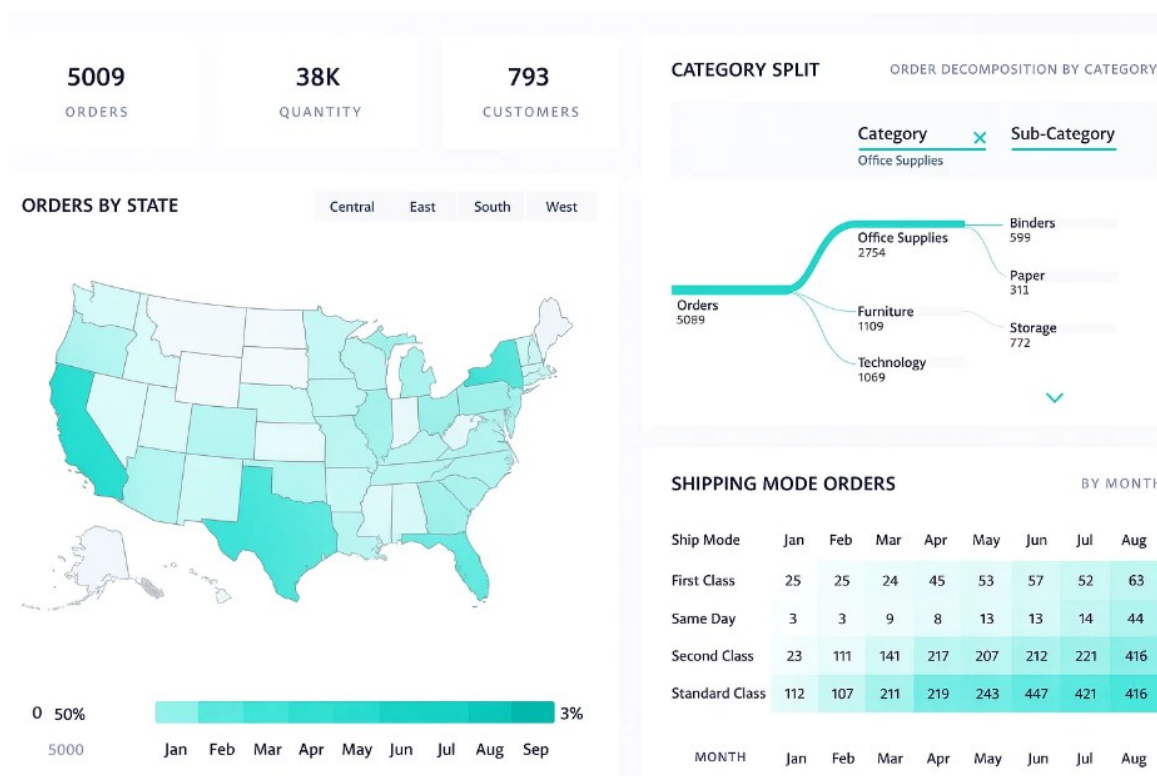
integruje s dalšími produkty Microsoftu, což usnadňuje analýzu a vizualizaci dat v rámci organizací. Qlik je další populární nástroj, který se zaměřuje na asociativní analýzu dat a umožňuje uživatelům objevovat skryté souvislosti v datech.

Technologie používané pro Big Data se neustále vyvíjejí a zlepšují, což umožňuje organizacím efektivněji zpracovávat a analyzovat velké objemy dat. Distribuované systémy jako Apache Hadoop a Spark, NoSQL databáze, analytické nástroje jako R a Python, a nástroje pro vizualizaci dat jako Tableau a Power BI hrají klíčovou roli v této transformaci. Jak ukazuje výzkum, efektivní využití těchto technologií může organizacím poskytnout konkurenční výhodu a umožnit jim lépe reagovat na měnící se tržní podmínky a požadavky zákazníků.

1.4 Power BI a jeho využití pro analýzu Big Data

Power BI, vyvinutý společností Microsoft, je v současnosti jedním z nejvýznamnějších nástrojů pro analýzu dat, zejména v kontextu moderní digitalizace a práce s Big Data. Tento software umožňuje integraci dat z různorodých zdrojů, jejich analýzu a vizualizaci do interaktivních formátů. Podle Microsoftu (2024) je Power BI Desktop bezplatná aplikace, která umožňuje uživatelům připojovat data z různých zdrojů, transformovat je a vizualizovat. Používá se především pro tvorbu interaktivních reportů a analýz. Mezi hlavní funkce patří čištění a transformace dat pomocí Power Query, tvorba vizuálních reportů a jejich sdílení přes Power BI službu. Aplikace je pravidelně aktualizována, aby přinášela nové funkce pro uživatele. DATA IDEOLOGY (2024) uvádí, že Big Data v Power BI označují objemné datové sady, které je složité zpracovat a analyzovat kvůli jejich velikosti a struktuře. Architektura Power BI je navržena tak, aby propojovala, zpracovávala a vizualizovala data z různých zdrojů, což z ní dělá ideální nástroj pro analýzu velkých dat. Výzva však spočívá v optimalizaci výkonu a zajištění toho, aby data byla spravovatelná a smysluplná.

Na obrázku 3 je zobrazen logistický dashboard vytvořený v Power BI. Tento logistický dashboard poskytuje souhrnný pohled na vývoj objednávek a jejich strukturu v rámci Spojených států. V horní části jsou zobrazeny základní metriky: celkový počet objednávek (5009), množství zboží (38 tisíc kusů) a počet zákazníků (793). Tyto údaje slouží jako rychlý přehled o celkovém rozsahu obchodní aktivity. Ve spodní části dashboardu se nachází přehled způsobu doručení objednávek v průběhu jednotlivých měsíců. Nejvíce se využívá „Standard Class“, přičemž vrchol poptávky je patrný v měsících červen až srpen. To naznačuje sezónnost objednávek a může být důležité pro plánování kapacit dopravců. Pomocí dashboardu získáme rychlou a přehlednou analýzu dat, což podporuje efektivní rozhodování v logistice.



Obrázek 3 Logistický dashboard v Power BI (NUMERRO, 2023)

1.5 Azure Blob Storage a Big Data

Microsoft (2023) uvádí, že Azure Blob Storage je cloudové řešení, se kterým je možné ukládat objekty, které jsou navrženy k uchování velkého množství nestrukturovaných dat. Data mohou být textová i binární. Služby Azure Blob Storage jsou optimalizovány pro širokou škálu scénářů, včetně distribuce obsahu, zálohování a archivace dat, ale především pro analýzu velkých dat, kde Microsoft Azure poskytuje škálovatelné a efektivní prostředí. Díky podpoře protokolů HTTP/HTTPS a integraci s různými analytickými nástroji přímo v Microsoft Azure je umožněn snadný přístup k uloženým datům. Jejich zpracování probíhá na dálku, což je klíčové pro moderní datovou analytiku.

Zpracování velkých dat lokálně v počítači je velmi náročné na výpočetní výkon a může trvat značné množství času. Vzhledem k tomu, že tradiční počítače mají omezenou kapacitu paměti a výpočetních zdrojů, provádění operací na velkých objemech dat může vést k extrémně dlouhým dobám zpracování, přetížení systému a v některých případech i k nemožnosti dokončit analýzu. To platí zejména pro podniky a organizace, které pracují s obrovskými soubory, například v logistice, financích nebo zdravotnictví, kde je třeba analyzovat terabyty až petabyty dat. Azure Blob Storage a jeho integrace s cloudovými výpočetními službami, jako je Azure Data Lake Storage Gen2 nebo Azure Synapse Analytics, představují řešení tohoto problému. Podle Microsoftu (2023) „Cloudová infrastruktura umožňuje škálovatelné zpracování dat, což

znamená, že výpočetní výkon lze dynamicky přizpůsobit podle potřeby. Namísto toho, aby podniky investovaly do drahého hardwaru, mohou využívat výpočetní zdroje na vyžádání a platit pouze za skutečně využitou kapacitu.“ Díky tomu mohou provádět analýzy v reálném čase a získávat cenné poznatky mnohem rychleji, než by bylo možné při lokálním zpracování.

Další výhodou využití Azure Blob Storage pro Big Data je možnost efektivního řízení nákladů. Microsoft (2023) na svém učicím portálu uvádí, že pomocí zásad správy životního cyklu lze automatizovat přesun dat mezi různými úrovněmi přístupu (horká, studená, archivní), což pomáhá minimalizovat náklady na skladování dat při zachování jejich dostupnosti. Kromě toho je možné data distribuovat mezi různá geografická umístění, což zajišťuje vyšší spolehlivost a bezpečnost ve srovnání s tradičními lokálními řešeními.

Z těchto důvodů je cloudové řešení, jako je Azure Blob Storage, ideální volbou pro práci s Big Data. Poskytuje nejen výkonné a škálovatelné úložiště, ale také umožňuje rychlé a efektivní zpracování obrovských objemů dat, což organizacím pomáhá dosáhnout lepší efektivity a získávat relevantní poznatky v reálném čase.

1.6 Využití Big Data v logistice

Big Data hrají v logistice jednu z klíčových rolí při optimalizaci procesů, zlepšování efektivity a snižování nákladů podle výzkumu Kamble et al. (2020). Pokročilá analýza dat umožní přesné predikce poptávek, pomáhá s efektivní správou zásob a přináší lepší koordinaci logistických řetězců. Logistické firmy mohou díky analýze dat v reálném čase minimalizovat zpoždění, optimalizovat své procesy a rychle reagovat na neočekávané události.

Big Data přinášejí do oblasti logistiky důležité změny umožňující efektivní řízení operací a optimalizaci procesů. Podle společnosti DHL (2023) je klíčovou výhodou Big Data schopnost integrovat informace z různých zdrojů jako jsou data o dopravě, počasí, skladových zásobách nebo výkonnosti vozidel. Tato data nabízejí operátorům přehled o aktuální situaci což umožní okamžitou reakci na nepředvídatelné události a minimalizaci rizika zpoždění. Například prediktivní model dokáže predikovat podle DHL dopravní kongesce nebo poruchy v dodavatelském řetězci, čímž se zvyšuje spolehlivost doručení a snižují provozní náklady.

Jednou z hlavních výhod Big Data je optimalizace přepravy zboží. Pomocí analýzy historických i současných dat může společnost účinně plánovat přepravu a snížit náklady na logistiku sledováním aktuální dopravní situace a v reálném čase měnit trasu a vyhnout se jakémukoliv zpoždění. Jak uvádí DHL (2023) „nejlepší trasa nemusí být nutně nejrychlejší. Důležité jsou také otázky bezpečnosti. V případě zboží citlivého na otřesy se například volí trasy, které se vyhýbají dlažebním kostkám, zatímco otřesové senzory sledují bezpečnost

přepřavovaného zboží. Kromě toho mohou údaje o spotřebě paliva a jízdním chování, stejně jako údaje o životním prostředí naměřené pomocí senzorů vozidla, vypočítat ekologickou bilanci dodávek a zlepšit směřování z hlediska dopadu na životní prostředí.“ Tento přístup nejenom zvyšuje efektivitu, ale také přispívá k ochraně životního prostředí snížením spotřeby paliva a emisí.

Další klíčovou oblastí využití Big Data je podle společnosti DHL (2023) řízení rizik a zajištění transparentnosti dodavatelského řetězce. Díky schopnosti sledovat zásilky od výrobce až ke koncovému zákazníkovi se minimalizuje pravděpodobnost chyb a ztrát zásilek. Analytické vyhodnocení dat dále pomáhá předvídat a ovládat rizika spojená s přírodními katastrofami nebo politickou nestabilitou a umožní firmám přizpůsobit své operace k dosažení kontinuity služeb.

Využití Big Data může mít pro ekologické aktivity v oblasti logistiky celou řadu výhod. Monitorováním emisí a optimalizací využití vozidel mohou společnosti implementovat ekologicky šetrné strategie, které nejen zlepšují jejich pověst, ale současně snižují náklady. DHL například uvádí, že zavedení udržitelných iniciativ pomáhá dosahovat ekologických cílů a zvyšovat celkovou efektivitu podnikání.

Big Data také přispívají k individuálnímu přizpůsobení zákaznických služeb. Gottwald a Chocholáč (2022, s. 37) ve své učebnici podotýkají, že *„Tyto informační zdroje poskytují podnikům informace o zákaznících (informace o každém jednotlivém zákazníkovi, jako např. kolik minut strávil na e-shopu, jakou částku utratil, jak postupoval e-shopem do okamžiku realizace objednávky, jak se chová na sociálních sítích apod.) o dodavatelích, o ostatních partnerech, stejně jako informace o nákupních trendech převládajících na daném trhu atd. Informace, které mají podniky v současné době k dispozici, jsou již tak objemné, že je není možné prostřednictvím běžně dostupných nástrojů komplexně analyzovat. Komplexním zpracováním je myšleno provedení detailní analýzy všech dostupných informací ve snaze nalezení nových souvislostí a následně nových trendů v odvětví, ve kterém daný podnik působí.“* Studium preferencí a chování zákazníků mohou firmy přizpůsobit své služby individuálním potřebám s cílem zlepšit spokojenost a loajalitu zákazníků. Tento přístup napomáhá vylepšit uživatelský zážitek a predikovat změny v poptávkách k efektivnímu reagování na tržní trendy.

Big Data však hrají důležitou roli i při správě skladových zásob a kontrole skladování, což přispívá k efektivnímu průběhu logistických procesů. Podle DHL (2023) umožní sledování a monitorování dat o zásobách pomocí systémů a senzorů získat přesné informace o aktuální poloze jednotlivých položek. Tato data jsou klíčová pro zajištění rychlé dostupnosti potřebného zboží a usnadní efektivní plánování skladových operací.

Analýza informací z inventárních systémů je užitečná pro identifikaci nedostatku zásob nebo nevyužitých skladových prostorů s cílem optimalizovat skladovací kapacitu a zabránit nákladnému nedostatku při dodávkách zboží. Podle DHL (2023) lze *„prognózy zásob provádět tak, aby předpovídaly očekávaný vzorec příchozích objednávek a dodávek během nadcházejících vrcholných a mimošpičkových sezón.“*

Schopnost předvídat budoucnost nejen zvyšuje efektivitu správy skladů, ale také přispívá k lepší spokojenosti zákazníka díky vyšší dostupnosti požadovaných výrobků a umožňuje společnostem mít schopnost rychle reagovat na změny v poptávkách a lépe reagovat na sezónní výkyvy, díky čemuž udržují svou konkurenceschopnost.

Využití Big Data přímo ve skladování usnadní identifikaci a odstranění nedostatků a snížení provozních nákladů. Použitím senzorů a pokročilých analytických nástrojů mohou společnosti optimalizovat umístění zboží ve skladech, čímž zkrátí dobu manipulace a urychlí celý proces logistiky.

1.7 Použití AI pro Big Data

Při analýze a zpracování Big Data hraje AI klíčovou roli, zejména v oblastech, kde je nutné efektivně pracovat s obrovskými objemy dat, která jsou různorodá, neúplná nebo dynamická. AI technologie, jako strojové učení (machine learning) a hluboké učení (deep learning), se široce využívají k extrakci hodnoty z dat a k predikci trendů, což je zásadní pro řadu průmyslových aplikací, včetně logistiky, financí, zdraví a marketingu. Nicméně, jak upozorňuje odborná literatura, AI může "halucinovat", což znamená, že při generování výstupů může poskytnout nesprávné nebo nereálné výsledky, pokud data nejsou kvalitní nebo jsou nedostatečná. Tento fenomén je důležitý zejména při aplikaci AI v logistice, kde je spolehlivost dat klíčová pro efektivní optimalizaci procesů.

- **Strojové učení a prediktivní analýza**

Jedním z hlavních způsobů, jak AI přispívá k využívání Big Data, je prostřednictvím strojového učení. Jak uvádí autor Matt Payne (2021), strojové učení umožňuje počítačům analyzovat data a automaticky se učit z vzorců a zkušeností bez explicitního programování. Tento přístup je ideální pro analýzu obrovských množství dat, protože modely strojového učení dokážou identifikovat složité vzory a vztahy, které by byly pro lidské analytiky těžko rozpoznatelné. Například v logistice lze strojové učení použít k predikci poptávky, optimalizaci tras, k analýze efektivnosti skladových operací nebo využití chatbotů v logistice.

- **Hluboké učení a zpracování obrazů**

Hluboké učení, které je podmnožinou strojového učení, využívá umělé neuronové sítě pro analýzu dat. Jak uvádí LeCun et al. (2015), hluboké učení je účinné při zpracování nestrukturovaných dat, jako jsou obrázky nebo zvukové signály. Například v oblasti logistiky se používá pro automatické rozpoznávání a třídění zásilek nebo pro detekci anomálií v dopravních datech. Tato technologie může také pomoci při analýze vizuálních dat z kamer ve skladech a při monitorování zařízení.

- **Prediktivní analýza pro zlepšení efektivity**

Prediktivní analýza je klíčovým nástrojem pro zlepšení efektivity v logistice, jak uvádí DHL (2024). Pomocí algoritmů strojového učení a analýzy historických dat mohou logistické společnosti předpovědět budoucí události, jako jsou výpadky v dodavatelském řetězci nebo změny v poptávce, což umožňuje optimalizaci zásob a plánování tras. Tato analýza pomáhá nejen předvídat možné problémy, ale také implementovat opatření, která umožní firmám flexibilně reagovat na změny a zlepšit tak celkovou efektivitu a spolehlivost logistických operací. DHL (2024) dále zdůrazňuje, že prediktivní analytika je neocenitelná pro optimalizaci tréninků a předvídaní údržby, což umožňuje firmám provádět preventivní kroky, aby se vyhnuly neplánovaným prostojům a zvýšily celkovou efektivitu procesů. Tento přístup přispívá k výraznému zefektivnění provozu a zvyšuje konkurenceschopnost firem na dynamickém trhu.

- **Chatboti v logistice**

Chatbot technologie v logistice využívající AI má značný dopad na zlepšení efektivity a spokojenosti zákazníků. Jak uvádí DHL (2024), AI-powered chatboti umožňují firmám poskytovat zákaznický servis 24 hodin denně, 7 dní v týdnu, čímž zajišťují okamžité odpovědi na dotazy, sledování zásilek, změny objednávek a mnoho dalších služeb. Tento pokrok v oblasti automatizace nejenže zlepšuje interakce se zákazníky, ale zároveň snižuje náklady na pracovní sílu a optimalizuje procesy.

Effectivesoft (2024) podtrhuje, že chatboti integrovaní do logistických aplikací umožňují personalizovanou interakci, což zvyšuje úroveň zákaznické spokojenosti a efektivitu celkového procesu. Díky tomu jsou podniky schopné pružně reagovat na požadavky zákazníků a zároveň minimalizovat chybovost a časovou náročnost při poskytování služeb.

DHL (2024) dále uvádí, že chatboti v logistice nejen zrychlují komunikaci s koncovými uživateli, ale také pomáhají ve vnitřních procesech, jako je správa zásob, sledování dopravních podmínek a predikce výzev v dodavatelském řetězci. AI tedy přispívá k celkové digitalizaci a modernizaci logistických operací, což vede k větší efektivitě a konkurenceschopnosti na trhu.

1.8 Vychystávání

Podle Quadera a Castillo-Villara (2018) je vychystávání procesem výběru produktů ze skladu za účelem splnění zákaznických objednávek. Tento proces představuje nejvíce pracně náročnou a nákladnou činnost ve skladu, což zdůrazňuje jeho význam pro celkovou efektivitu logistických operací. Tompkins et al. (2010) uvádějí, že vychystávání objednávek tvoří přibližně 55 % provozních nákladů skladu a cestovní čas představuje přibližně 60 % celkového času vychystávacích činností.

Sekvenční vychystávání je dle SSI SCHAEFER (2025) metoda vychystávání objednávek nebo materiálu, která se využívá v logistice a skladovém hospodářství k efektivnímu shromažďování produktů či materiálu. Tento přístup se podle výše uvedeného internetového zdroje často uplatňuje v prostředích s vysokým objemem objednávek a složitou strukturou skladových zásob, kde je nutné optimalizovat pohyb pracovníků nebo automatizovaných systémů. Sekvenční vychystávání nachází uplatnění v různých odvětvích, zejména tam, kde je kladen důraz na přesnost a rychlost dodávek. Například v automobilovém průmyslu je tato metoda využívána pro přípravu komponentů na montážních linkách.

Existují různé metody vychystávání, které se liší podle typu skladu a specifických požadavků na operace. De Koster et al. (2012) uvádějí, že minimalizace cestovní vzdálenosti je hlavním cílem při návrhu a optimalizaci skladových operací. Mezi běžné metody vychystávání patří:

- **Picker-to-Parts:** V této metodě pracovníci procházejí vychystávací oblastí a sbírají požadované položky. Tato metoda je vhodná pro sklady s vysokou variabilitou objednávek a nízkou automatizací.
- **Parts-to-Picker:** Automatizované jeřáby se pohybují po uličkách, vyzvedávají jednotkové náklady a přinášejí je na vychystávací pozici. Tato metoda je efektivní pro sklady s vysokou úrovní automatizace a standardizovanými objednávkami.

Optimalizace vychystávacích tras je klíčovým faktorem pro zvýšení efektivity skladových operací. Ueno a Hirata (2024) uvádí, že optimalizace vychystávacích tras může vést k až 31% zlepšení efektivity v rámci celkové vzdálenosti, kterou pracovníci urazí. Tito autoři vyvinuli optimalizační metodu pro provoz omezeného počtu pracovníků nebo vychystávacích robotů v konkrétní oblasti, která zahrnuje řešení náhlých změn v pořadí vychystávání nebo blokáce uliček.

Moderní technologie hrají klíčovou roli při zlepšování efektivity vychystávacích procesů. Luu et al. (2023) uvádějí, že kombinatorická optimalizace a modely dedikovaného skladování mohou výrazně zlepšit operace vychystávání objednávek. Použití softwaru jako

umožňuje optimalizaci vychystávacích tras a rozhodnutí o umístění skladových položek, což vede k lepší efektivitě a snížení nákladů.

Budoucí výzkum v oblasti vychystávání by měl zahrnovat další integraci pokročilých technologií, jako jsou umělá inteligence a strojové učení, pro zlepšení predikce poptávky a optimalizace skladových operací. Luu et al. (2023) také zdůrazňují potřebu propojení teoretických konceptů s praktickými aplikacemi, aby se překlenula mezera mezi akademickým výzkumem a řízením skladových operací.

Kromě plně automatizovaných řešení existují i poloautomatické systémy, které kombinují manuální a automatizované prvky pro zvýšení efektivity vychystávacího procesu. Tyto systémy zahrnují technologie jako Pick by Light, Pick by Vision a Pick by Voice.

Uvedené metody umožňují pracovníkům rychlejší a přesnější zpracování objednávek. Níže budou podrobně popsány tyto nejčastěji využívané poloautomatické metody.

- **Pick by Light**

Šrámková (2022) uvádí, že systémy Pick by Light, známé v oblasti logistiky, představují metodu zpracování objednávek a jejich vyskladnění. Na základě údajů v podnikovém systému se rozsvítí příslušné regálové pozice, čímž se pracovníkům usnadní orientace při vychystávání zboží. Tento systém zároveň slouží jako kontrolní mechanismus Poka Yoke, který minimalizuje chyby. Tato technologie je zobrazena na obrázku č. 4.



Obrázek 4 Pick by Light (PICK TO LIGHT SYSTEMS, 2025)

- **Pick by Vision**

Klumpp a Ruiner (2021) uvádějí, že systém Pick by Vision funguje pomocí chytrých brýlí a obdobně jako jiné metody vychystávání zvyšuje efektivitu a snižuje chybovost, čímž přináší časovou úsporu. Zaměstnanci díky brýlím vidí důležité informace týkající se vychystávání, což usnadňuje orientaci v procesu. Nicméně tato technologie má i své nevýhody, zejména negativní dopady na pracovníky, kteří si často stěžují na bolesti hlavy a očí.

Internetový zdroj LUCA (2023) doplňuje, že Pick by Vision funguje na principu rozšířené reality. Operátor si nasadí datové brýle připojené k systému řízení skladu prostřednictvím WLAN. Po spuštění objednávky malý projektor promítá informace do zorného pole pracovníka, který vidí umístění zboží a potřebné množství. Mezi hlavní výhody tohoto systému patří minimální interakce s okolím, možnost úpravy skladových zásob v reálném čase a snížení chybovosti. Na obrázku č. 5 jsou zobrazeny brýle pro vychystávání.



Obrázek 5 Brýle pro vychystávání pomocí Pick by Vision (LUCA, 2023)

- **Pick by Voice**

Pick by Voice je bezpapírová technologie vychystávání, která využívá hlasové pokyny k navigaci skladových pracovníků při plnění objednávek. Jak uvádí internetový zdroj THREAD IN MOTION (2021), operátoři používají sluchátka s mikrofonom připojená k mobilnímu počítači, který zpracovává hlasové povely a směřuje pracovníky ke správné vychystávací pozici. Systém zároveň umožňuje ověření místa a položky pomocí rozpoznávání hlasu a v případě nesprávného zadání poskytuje okamžitou korekci. Pro zvýšení přesnosti může být doplněn o čárové kódy nebo RFID technologii.

Klumpp a Ruiner (2021) dodávají, že Pick by Voice je široce využíván v automobilovém průmyslu, kde je strukturován podle principů Just in Time (JIT) a Just in Sequence (JIS). Mezi hlavní výhody této technologie patří snížení chybovosti, zrychlení procesu vychystávání a efektivnější zaškolování nových zaměstnanců. Díky hlasovému

ovládání mají pracovníci volné ruce i zrak, což usnadňuje manipulaci se zbožím a zlepšuje ergonomii práce.



Obrázek 6 Pick by Voice (THREAD IN MOTION, 2021)

2 ANALÝZA POSKYTNUTÝCH DAT

Druhá kapitola se zaměřuje na aplikaci teoretických poznatků do praxe, konkrétně na detailní analýzu Big Data poskytnutých společnostmi ŠKODA AUTO a.s. Cílem této kapitoly je provést podrobný rozbor logistických dat ze sekvenčního vychystávání v závodě Kvasiny a popis, jakým způsobem byly data zpracovány. V úvodu kapitoly je nejprve představena historie a charakteristika společnosti ŠKODA AUTO a.s., která zajišťuje potřebný kontext pro pochopení interního fungování firmy a významu daných logistických procesů. Popsány zde budou také odvolávkové systémy BMA a SSW, které jsou ve společnosti využívány. Následně je pozornost věnována úvodu do problematiky sekvenčního vychystávání, které představuje klíčový logistický proces pro zásobování montážních linek správnými díly ve správném pořadí. Tento způsob vychystávání významně ovlivňuje efektivitu výroby, minimalizuje zásoby na lince a zvyšuje flexibilitu při řízení výroby.

Stěžejní část kapitoly se zabývá charakteristikou a strukturou dat, která byla analyzována. Data pocházejí z reálného provozu ŠKODA AUTO a. s. a obsahují detailní záznamy o vychystávaných dílech. Jedná se o rozsáhlý objem dat, který dokumentuje vychystávání dílů pro stovky tisíc vozidel. Získané informace slouží jako základ pro kvantitativní analýzu, jejímž cílem je identifikovat úzká místa, trendy ve spotřebě a příležitosti pro optimalizaci. Důležitou součástí kapitoly je rovněž popis způsobu zpracování dat s využitím cloudového úložiště Azure Blob Storage, které bylo použito kvůli objemu dat překračujícím možnosti lokálního hardwaru. Proces zahrnuje přípravu dat, jejich nahrání do cloudu, propojení s Power BI a následné úpravy nezbytné pro analytické využití. Tento přístup demonstruje praktické využití moderních technologií v oblasti Big Data a datové analytiky v podnikovém prostředí. Kapitola tak poskytuje přehled o tom, jak zpracovat reálná data z interního prostředí.

2.1 Historie a charakteristika společnosti ŠKODA AUTO a. s.

Podle internetového zdroje ŠKODA AUTO (2025) je společnost jednou z nejvýznamnějších automobilových značek nejen v České republice, ale i na globálním trhu. Sídlo firmy se nachází v Mladé Boleslavi, odkud řídí své operace jako součást koncernu Volkswagen Group. Toto spojení jí umožňuje čerpat z pokročilých technologií, rozsáhlých distribučních sítí a zdrojů pro inovace, které jsou klíčové pro udržení konkurenceschopnosti. Jak uvádí ŠKODA AUTO (2025), výrobní závody společnosti jsou rozmístěny nejen v České republice (Mladá Boleslav, Kvasiny, Vrchlabí), ale také v zahraničí, například na Slovensku, v Číně a Indii, kde se produkce přizpůsobuje lokálním trhům a potřebám zákazníků.

Podle informací z roku 2025 se ŠKODA AUTO a. s. zaměřuje na rozvoj udržitelných technologií, přičemž elektromobilita je jedním z hlavních pilířů její strategie. ŠKODA AUTO (2025) uvádí, že společnost v posledních letech významně rozšířila svou nabídku o modely s alternativními pohony, včetně elektrických vozů řady Enyaq, které reflektují celosvětový trend směrem k ekologičtější mobilitě. Kromě toho firma investuje do výzkumu a vývoje autonomních technologií a digitalizace, což jí umožňuje držet krok s rychle se měnícími požadavky trhu.

ŠKODA AUTO (2025) také zdůrazňuje, že společnost klade velký důraz na environmentální odpovědnost. Firma se zavázala k dosažení uhlíkové neutrality ve svých provozech, a to prostřednictvím využívání obnovitelných zdrojů energie, recyklace materiálů a implementace technologií snižujících emise. Kromě toho podporuje řadu komunitních projektů zaměřených na ochranu životního prostředí a sociální rozvoj.

Historie společnosti, jak uvádí zdroj ŠKODA AUTO (2025), sahá až do roku 1895, kdy byla založena jako Laurin & Klement, firma specializující se na výrobu jízdních kol a později motocyklů. První automobil, Voiturette A, byl představen v roce 1905, což odstartovalo éru automobilové výroby. V roce 1925 došlo ke spojení s plzeňským strojírenským podnikem Škoda, což přineslo další rozvoj a modernizaci. Po druhé světové válce byla společnost znárodněna a pokračovala v produkci pod značkou ŠKODA. V roce 1991 se stala součástí koncernu Volkswagen, což znamenalo významné investice a technologický pokrok.

Podle zdroje ŠKODA AUTO (2025) je společnost jedním z největších českých exportérů a zaměstnavatelů, který nabízí pracovní příležitosti pro desítky tisíc lidí nejen v České republice, ale i v zahraničí. Firma se zaměřuje na rozvoj talentů prostřednictvím odborných školení a programů, což jí umožňuje udržet si konkurenceschopnost a inovativnost. Její vozy jsou známé pro svou kvalitu, spolehlivost a inovativní technologie, což z nich činí oblíbenou volbu zákazníků po celém světě. ŠKODA AUTO (2025) konstatuje, že společnost i nadále investuje do výzkumu a vývoje, aby mohla nabízet moderní a konkurenceschopné produkty. Díky své bohaté historii a schopnosti adaptovat se na měnící se tržní podmínky si ŠKODA AUTO udržuje silnou pozici mezi předními světovými automobilkami.

2.2 Layout svařovny v závodě Kvasiny

Efektivní uspořádání výroby pomáhá optimalizovat logistiku, snižovat náklady a zvyšovat produktivitu. Svařovna ve ŠKODA AUTO a. s. je navržena tak, aby materiál plynule procházel procesem, minimalizovala se manipulace a efektivně se využil prostor. Rozložení odpovídá nejen výrobní sekvenci, ale i skladování a zásobování pracovišť.

Svařovna je rozdělena do jasně definovaných sekcí, kde probíhají operace podle technologických požadavků. Pracoviště jsou organizována tak, aby materiál přicházel plynule a minimalizovaly se prostoje. Klíčovou roli v řízení zásob hraje sekvenční vychystávání, které ve ŠKODA AUTO a. s. využívá systémy jako Pick to Light nebo Pick by Vision. Tyto technologie zpřesňují a zrychlují vychystávání komponentů, čímž snižují chybovost a zvyšují efektivitu.

Big Data mohou dále optimalizovat logistiku svařovny. Analýza dat o pohybu materiálu může odhalit úzká místa ve výrobě, která lze odstranit. Prediktivní modely mohou předvídat spotřebu materiálu a zlepšit jeho distribuci. Napojení na analytické nástroje umožní modelovat různé scénáře změn v uspořádání svařovny a hodnotit jejich dopad na výrobu a logistiku.

Současné uspořádání svařovny odpovídá principům efektivní výroby, ale digitalizace a pokročilá analýza dat mohou přinést další zlepšení. Propojení logistických procesů s datovou analytikou je klíčem k moderní výrobě, kde rozhodování stále více vychází z reálných dat a predikcí.

2.3 Odvolávkové systémy ve ŠKODA AUTO a. s.

Tato podkapitola se zaměřuje na interní objednávkové systémy „SSW“ a „BMA“, které jsou využívány v závodě ŠKODA AUTO a.s. Tyto systémy jsou klíčové pro efektivní řízení materiálových toků a minimalizaci chybovosti. Díky jejich implementaci se závod pyšní minimální chybovostí, dosahující pouze dvě až tři závady na milion dílů. Tyto systémy dále pracují se systémy FIS, CarRFID.

2.3.1 Systém BMA

Dle Jehličky je (2022) systém BMA automatický odvolávkový systém vyvinutý společností Volkswagen v Německu. Název pochází z německého "Bedarfsorientierter Materialabruf", což znamená odvolání materiálu orientovaného na poptávku. Tento systém využívá matematickou nerovnici k výpočtu potřebného množství materiálu, který je třeba dodat na výrobní linku. Systém čerpá data z dalších výrobních systémů, jako jsou FIS a CarRFID, které identifikují vůz ve výrobním toku.

Dále autor uvádí, že prvkem systému BMA je několik proměnných: "stav" (aktuální množství materiálu na místě potřeby), "objednáno" (množství odvolaného materiálu), "potřeba" (počet materiálu potřebného k pokrytí zakázek mezi odvolávkovým bodem a místem spotřeby) a "rezerva" (množství materiálu navíc pro případ zpoždění nebo chybné dodávky). Tento systém umožňuje nastavit rychlost vytváření odvolávek.

Na konec autor zmiňuje, že je systém BMA podporován systémem FIS, který poskytuje informace o vozech postupujících výrobou. Například, když se vůz dostane na takt 76, systém BMA zahájí proces odvolání materiálu, který bude potřeba na taktu 136. Tento proces zahrnuje odvolávku, vychystání a dopravení materiálu k výrobní lince. Systém LOGIS poté přijme odvolávku a po vyskladnění materiálu tuto skutečnost oznámí systému BMA, který aktualizuje stav rovnice.

2.3.2 Modul SSW

Podle Jehličky (2022) modul SSW, který je součástí systému Andon (tj. systém, který se rozděluje na dva podsystémy na základě použitých modulů. Prvním modulem je SSW, jenž zaznamenává odvolání prostřednictvím malých KLT přepravek. Druhý modul, AWB, je zodpovědný za materiál přepravovaný pomocí GLT palet). Systém SSW tedy zajišťuje odvolávání materiálů, které jsou na montážní linku dopraveny v KLT přepravkách. Tento proces využívá speciální zátěžové senzory, které jsou umístěny na skluzovém regálu. Umístění senzorů se liší podle typu regálu a množství dílů v přepravce, což závisí na rychlosti spotřeby dílů. Senzory mohou být umístěny například pod druhou nebo čtvrtou přepravku.

Jehlička (2022) dále uvádí, že tyto senzory fungují bezdrátově, což umožňuje systému automaticky posílat informace o odebraném množství do automatického skladu malých dílů. V závodě funguje automatický sklad KLT, který zvládne vychystat a zaskladnit až 500–700 KLT za hodinu. Před zaskladněním se kontroluje velké množství materiálu, protože dodavatelé často přivázejí pomíchaný materiál na jedné paletě.

2.4 Úvod do problematiky sekvenčního vychystávání

V automobilovém průmyslu hraje logistika a řízení zásob klíčovou roli v zajištění plynulé výroby a minimalizaci prostojů. Jedním z nejdůležitějších procesů v dodávání materiálu na montážní linky ve ŠKODA AUTO a. s. je sekvenční vychystávání dílů, které umožňuje správné a včasné dodání požadovaných komponent na montážní linky. Tento proces má zásadní vliv na efektivitu výroby, snižování nákladů a optimalizaci skladových zásob.

Sekvenční vychystávání představuje metodu řízení materiálového toku, při níž jsou díly připravovány a expedovány v přesně stanoveném pořadí podle výrobního plánu. Tento systém eliminuje potřebu nadměrného skladování přímo na montážní lince a zajišťuje, že montážní pracovníci dostanou pouze ty komponenty, které jsou v daném momentě potřebné.

V rámci této diplomové práce byla získána rozsáhlá datová sada ze sekvenčního vychystávání ve ŠKODA AUTO a. s., která umožňuje detailní analýzu procesů spojených

s tokem materiálu ve výrobě. Cílem této kapitoly je seznámení se strukturou těchto dat, identifikace klíčových parametrů a jejich významu pro další analýzu.

2.5 Charakteristika a zdroj dat

Pro analýzu byly využity reálné provozní záznamy ze sekvenčního vychystávání ve ŠKODA AUTO a. s. Jedná se o data vychystávaných dílů pomocí modulu SSW a AWB. Tato data poskytují přehled o skladových pohybech a využití jednotlivých dílů.

Datové soubory obsahuje více než **12 GB informací** a přibližně **12 miliard znaků**, které se nachází ve **232 milionech řádků**. Poskytnutá data jsou datována od června 2024 do konce roku. Tato data umožňují detailní zkoumání skladového hospodářství a vychystávacích operací. Vizuální forma dat je zobrazena na obrázku č. 7.

WK_M	MO	KNR_7	SEK	SEKVD_ID	CDILU	Množství
33	PS7	0314347	S	M10A	57H800375A	1,00
33	PS7	0314347	S	M10A	57H857038 4PK	1,00
33	PS7	0314347	S	M10A	5E3959753R	2,00
33	PS7	0314347	S	M11A	565959565A WHI	1,00
33	PS7	0314347	S	M11A	3G0959857B WHS	1,00
33	PS7	0314347	S	M13A	5R3980568F	1,00
33	PS7	0314347	S	M13A	5E3827566A	1,00
33	PS7	0314347	S	M20A	57H880204D	1,00
33	PS7	0314347	S	M21A	57H035816B	1,00
33	PS7	0314347	S	M22A	3WA907007F	1,00
33	PS7	0314347	S	M22A	5QS919300B	1,00
33	PS7	0314347	S	M22A	5QS907530E	1,00
33	PS7	0314347	S	M22A	5WA937084AG	1,00
33	PS7	0314347	S	M22A	5WA959436AD	1,00

Obrázek 7 Vizualizace dat z interního systému ŠKODA AUTO (autor)

Data byla získána z interních systémů společnosti a zahrnují následující hlavní atributy:

- **WK_M (Závod montáže)** – Číselné označení závodu, kde probíhá montáž.
- **MO (Montážní operace)** – Kód oddělení, kde se montážní operace provádí.
- **KNR_7 (Kód vozidla)** – Interní číselné označení vozidla, kterému bude dále vytvořen VIN kód.
- **SEK (Sekvenční příznak)** – Kategorie skladového sortimentu.
- **SEKVD_ID (Sekvenční ID vychystávaných dílů)** – Unikátní klasifikace dílů podle jejich typu a způsobu použití.
- **CDILU (Číslo dílu)** – Katalogové číslo součástky, pod kterým je evidována v databázi.
- **Množství** – Počet kusů daného dílu, který byl vychystán v rámci sekvenčního procesu.

Každý z těchto atributů hraje důležitou roli při řízení materiálových toků a jeho analýza umožňuje identifikaci trendů, optimalizaci zásob a predikci spotřeby jednotlivých komponent.

2.6 Význam dat pro analýzu logistických procesů

Z pohledu na analyzovaná data lze určit, že průměrně se k jednomu vozidlu stahuje 228 dílů materiálu v rámci sekvenčního vychystávání. Celkový rozsah dostupných dat zahrnuje záznamy pro **250 886 vozidel**, což umožňuje detailní pohled na strukturu spotřebovávaných dílů a jejich distribuci v rámci výrobního procesu. Ve výrobním závodě ŠKODA AUTO a. s. v Kvasinách je denně vyrobeno přibližně 1 190 vozidel, což dokládá rozsah a intenzitu procesů souvisejících se sekvenčním vychystáváním.

Dostupná data obsahují širokou škálu informací, které umožňují analyzovat nejen množství a četnost použití jednotlivých komponent, ale také trendy ve spotřebě materiálu v závislosti na výrobním plánu. Významným aspektem této analýzy je možnost sledování skladových zásob a optimalizace logistických operací s cílem minimalizace nadměrných zásob, které mohou vést k neefektivnímu využívání skladových kapacit.

Díky těmto datům lze přesně identifikovat, které díly mají nejvyšší obrátkovost a jsou tedy klíčové pro plynulý chod výroby. Naopak lze odhalit i komponenty s nízkým využitím, které mohou představovat příležitost pro optimalizaci skladového hospodářství. Podrobná analýza těchto dat pomůže v identifikaci současných trendů. Pokud by data obsahovala časový údaj, bylo by možné předpovědět budoucí potřebu jednotlivých komponent na základě historických vzorců spotřeby.

Dalším důležitým aspektem této analýzy je možnost identifikace anomálií nebo nepravidelností v sekvenčním vychystávání. Zlepšení predikčních modelů a implementace pokročilých analytických metod, jako je využití Power BI nebo strojového učení, by mohlo významně přispět ke zvýšení efektivity celého procesu.

Data ze sekvenčního vychystávání poskytují komplexní pohled na logistické operace ve ŠKODA AUTO a. s. a umožňují hlubší pochopení dynamiky výroby. Jejich správná interpretace a využití analytických nástrojů mohou vést ke zvýšení efektivity nejen v oblasti řízení zásob, ale i ve strategickém plánování logistiky a výroby. V následujících částech bude tato analýza dále rozpracována s využitím pokročilých metod vizualizace a datové analytiky.

2.7 Propojení Big Data s Azure Blob Storage

Vzhledem k tomu, že autorova specializace je logistika, nikoliv informační technologie, bylo nutné celý proces nahrávání dat do cloudového úložiště Microsoft Azure Blob Storage samostatně nastudovat. Tato část práce dokumentuje konkrétní postup, který autor realizoval,

a ukazuje na složitost i technickou náročnost, která byla spojena s prací s velkými objemy dat v cloudovém prostředí.

Prvotní snahou bylo nahrát data přímo do Power BI. Jednalo se o soubory ve formátu .txt obsahující miliony řádků s informacemi o sekvenčním vychystávání. Během testování se ukázalo, že lokální zařízení nezvládá zpracování takto rozsáhlých dat, a tudíž docházelo k pádu softwaru kvůli přetížení paměti a k výraznému zpomalení načítání. To vedlo k rozhodnutí využít cloudové řešení, které by umožnilo stabilní a výkonnější práci s daty.

2.7.1 Seznámení s prostředím Microsoft Azure

Vzhledem k absenci předchozích zkušeností autora s cloudovými technologiemi bylo nutné nejprve prostudovat základní principy fungování Microsoft Azure. MICROSOFT LEARN (2025a) uvádí, že prvním krokem je založení tzv. účtu úložiště (Storage Account), který tvoří základní stavební jednotku pro ukládání dat v Azure. Pro tuto práci bylo zvoleno studentské předplatné **Azure for Students**, které umožnilo využití služeb bez nutnosti platby.

Na obrázku č. 8 je zobrazen proces vytváření účtu úložiště. V tomto formuláři bylo nutné vyplnit následující údaje:

- **Skupina prostředků:** zde byla vytvořena vlastní skupinu s názvem **SkodaAutoData**, která slouží k logickému seskupení všech souvisejících komponent.
- **Název účtu úložiště:** **skodaaautodata** – tento název musí být v Azure globálně jedinečný a je používán v URL adrese pro přístup k datům.
- **Oblast (region):** **(Europe) Poland Central**, což je doporučená lokalita pro uživatele ze střední Evropy z hlediska latence a dostupnosti služeb.
- **Primární služba:** **Azure Blob Storage nebo Azure Data Lake Storage Gen2**, přičemž bylo využito Blob Storage pro práci s nestrukturovanými daty (textové soubory).
- **Výkon:** **Standard**, tedy varianta doporučená pro běžné scénáře – cenově dostupná varianta pro platící uživatele.
- **Redundance:** **Místně redundantní úložiště (LRS)** zajišťuje uložení dat ve třech kopiích v rámci jednoho datacentra.

Vytvořit účet úložiště ...

Vyberte předplatné, ve kterých chcete vytvořit nový účet úložiště. Pokud chcete organizovat a spravovat účet úložiště spolu s ostatními prostředky, zvolte novou nebo existující skupinu prostředků.

Předplatné *	Azure for Students
Skupina prostředků *	SkodaAutoData
Vytvořit nový	
Podrobnosti o instanci	
Název účtu úložiště * ⓘ	skodaautodata
Oblast * ⓘ	(Europe) Poland Central
Nasazení do rozšířené zóny Azure	
Primární služba ⓘ	Azure Blob Storage nebo Azure Data Lake Storage Gen2
Výkon * ⓘ	<input checked="" type="radio"/> Standard: Doporučeno pro většinu scénářů (účet pro obecné účely verze 2)
	<input type="radio"/> Premium: Doporučeno pro scénáře, které vyžadují nízkou latenci.
Redundance * ⓘ	Místně redundantní úložiště (LRS)

Předchozí

Další

Zkontrolovat a vytvořit

Obrázek 8 Vytvoření účtu úložiště (Microsoft Azure, 2025)

Po vyplnění všech údajů bylo kliknuto na „Zkontrolovat a vytvořit“, čímž bylo úložiště úspěšně založeno.

Poté co byl vytvořen samotný účet úložiště bylo nezbytné založit také kontejner, tedy logickou složku, ve které budou data uložena. Dále byl zvolen název kontejneru **bigdata**, který jednoznačně identifikoval účel složky pro uložení rozsáhlých textových souborů z oblasti sekvenčního vychystávání ve společnosti ŠKODA AUTO. Průběh je zobrazen na obrázku č. 9.

Při nastavování přístupových práv byla ponechána výchozí hodnota **Privátní (bez anonymního přístupu)**, čímž byla zajištěna maximální bezpečnost dat. Podle MICROSOFT LEARN (2025a) je pro výchozí účty Azure doporučeno využívat právě tuto možnost, aby nedošlo k neautorizovanému přístupu k uloženým datům. Vytvoření kontejneru bylo dokončeno kliknutím na tlačítko „Vytvořit“.

Nový kontejner



Název *

bigdata ✓

Úroveň anonymního přístupu ⓘ

Privátní (bez anonymního přístupu) ▾

i Úroveň přístupu je nastavená na privátní, protože u tohoto účtu úložiště je anonymní přístup zakázaný.

▾ Pokročilé

Vytvořit

Poslat zpětnou vazbu 🗨

Obrázek 9 Vytvoření kontejneru (Microsoft Azure, 2025)

2.7.2 Nahrání dat do Azure Blob Storage pomocí portálu Azure


Po vytvoření účtu úložiště a kontejneru v rámci služby Azure Blob Storage bylo přistoupeno k samotnému nahrání dat. Šlo o přibližně 70 souborů ve formátu .txt, přičemž každý z nich obsahoval stovky tisíc až miliony řádků s informacemi o sekvenčním vychystávání v provozu společnosti ŠKODA AUTO.

Na rozdíl od doporučení MICROSOFT LEARN (2025a), kde je často preferován nástroj Azure Storage Explorer pro práci s velkými objemy souborů, bylo zvoleno přímé nahrání přes webové rozhraní portálu Azure. Tato volba byla motivována snahou pracovat výhradně v online prostředí bez nutnosti instalace dodatečného softwaru.

Jak je zřejmé z obrázku č. 10 pomocí funkce Nahrát objekt blob bylo vybráno všech 70 textových souborů, mezi nimi např. KVA (3).txt, KVB.txt atd., a nahrál je najednou do kontejneru bigdata. Nahrávací rozhraní umožňuje jednoduchou obsluhu a soubory bylo možné přetáhnout přímo do oblasti nahrávání nebo je vybrat ručně.

Nahrát objekt blob





Vybraly se 70 soubory: KVA (3).txt, KVB (2).txt, KVB.txt...
Sem přetáhněte soubory. nebo [Procházet soubory](#)

Pokud soubor už existuje, přepsat

▼ Rozšířené

Nahrát Poslat zpětnou vazbu

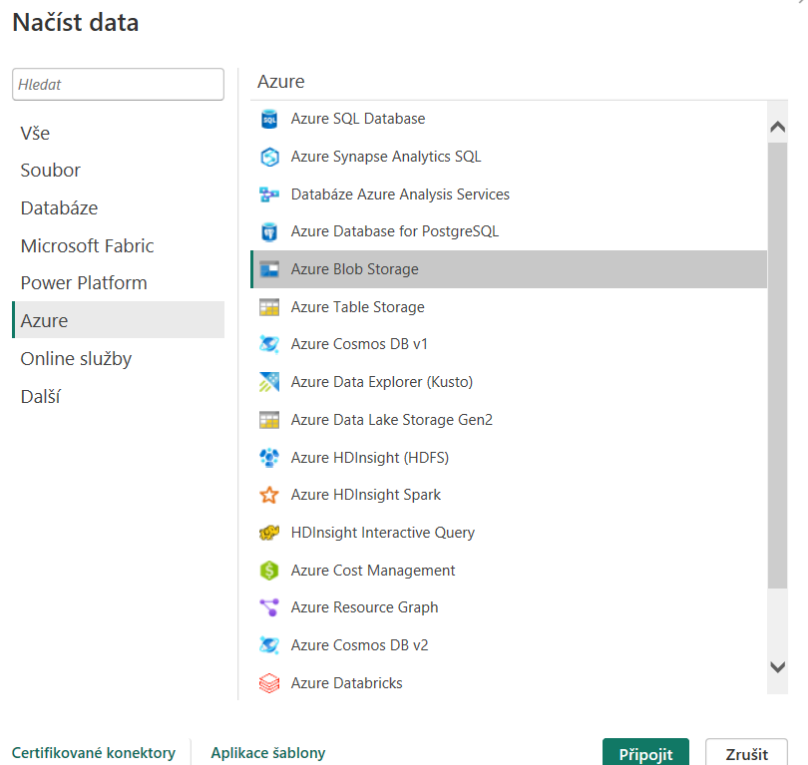
Obrázek 10 Nahrávání dat do kontejneru bigdata (Microsoft Azure, 2025)

Samotné nahrávání probíhalo v závislosti na stabilitě internetového připojení přibližně dvě hodiny. MICROSOFT LEARN (2025a) uvádí, že Azure Blob Storage je navržen pro efektivní přenosy i velmi rozsáhlých dat, přičemž stabilita nahrávání přes webové rozhraní je plně dostačující pro standardní projekty bez extrémních požadavků na výkon nebo automatizaci. Po dokončení nahrávání byla všechna data připravena pro další krok, tedy propojení s nástrojem Power BI a následnou analýzu.

2.7.3 Propojení Azure Blob Storage s Power BI

Po úspěšném nahrání všech datových souborů do kontejneru **bigdata** bylo nezbytné zajistit jejich propojení s analytickým nástrojem Power BI.

Podle MICROSOFT LEARN (2025b) je propojení Power BI s úložištěm Azure možné pomocí vestavěného konektoru „Azure Blob Storage“. Po otevření aplikace Power BI Desktop, byla zvolena možnost Načíst data, dále vybrána kategorie Azure a poté konkrétní konektor Azure Blob Storage, podle obrázku č. 11.



Obrázek 11 Načtení dat z Azure Blob Storage (Power BI, 2025)

Vzhledem k zabezpečení úložiště nebylo možné data načíst bez nastavení oprávnění k přístupu. MICROSOFT LEARN (2025b) uvádí, že nejčastěji se pro propojení Power BI s Azure Blob Storage využívá tzv. SAS token (Shared Access Signature), to je dočasný odkaz, který umožňuje přístup ke konkrétnímu prostředku v rámci omezeného časového období.

SAS token je vhodný především pro jednorázový nebo časově omezený přístup, například při sdílení dat s externími uživateli. V případě tohoto projektu však bylo nutné mít přístup k datům dlouhodobě a opakovaně, zejména kvůli opakovaným načítáním a aktualizacím reportů v Power BI. Z tohoto důvodu bylo vybráno alternativní řešení, připojení přes přímou URL adresu kontejneru.

Azure Blob Storage

Název účtu nebo adresa URL

OK

Obrázek 12 Propojení přes URL (Power BI, 2025)

Tento způsob připojení zajistil trvalý a stabilní přístup k datům bez nutnosti opakovaného generování přístupových tokenů. Jak ukazuje obrázek č. 12, adresa byla zadána přímo do pole „Název účtu nebo adresa URL“ a po potvrzení připojení Power BI úspěšně načel obsah kontejneru. Na obrázku č. 13 je zobrazeno, že po navázání spojení byly všechny soubory načteny ve formátu binárních dat, což je výchozí chování Power BI při práci s objekty v Azure Blob Storage. Tento formát je vhodný pro rychlý přenos, ale před samotnou analýzou je třeba data převést na čitelný tabulkový formát v Power Query.

<https://skodaautodata.blob.core.windows.net/bigdata>

Content	Name	Extension	Date accessed	Date modified	Date created	Attributes	Folder Path
Binary	KVA (10).txt	.txt	null	28.02.2025 8:56:58	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (11).txt	.txt	null	28.02.2025 8:56:55	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (12).txt	.txt	null	28.02.2025 8:56:51	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (13).txt	.txt	null	28.02.2025 8:56:54	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (14).txt	.txt	null	28.02.2025 8:56:51	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (15).txt	.txt	null	28.02.2025 8:55:52	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (16).txt	.txt	null	28.02.2025 8:55:40	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (17).txt	.txt	null	28.02.2025 8:55:21	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (18).txt	.txt	null	28.02.2025 8:55:13	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (19).txt	.txt	null	28.02.2025 8:53:56	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (2).txt	.txt	null	28.02.2025 8:55:32	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (20).txt	.txt	null	28.02.2025 8:53:43	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (21).txt	.txt	null	28.02.2025 8:53:43	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (22).txt	.txt	null	28.02.2025 8:53:33	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (23).txt	.txt	null	28.02.2025 8:53:30	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (24).txt	.txt	null	28.02.2025 8:52:41	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (25).txt	.txt	null	28.02.2025 8:52:39	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (26).txt	.txt	null	28.02.2025 8:52:34	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (27).txt	.txt	null	28.02.2025 8:52:34	null	Record	https://skodaautodata.blob.core.windows.net/t
Binary	KVA (28).txt	.txt	null	28.02.2025 8:52:28	null	Record	https://skodaautodata.blob.core.windows.net/t

Data v náhledu jsou kvůli omezení velikosti zkrácená.

Načíst Transformovat data Zrušit

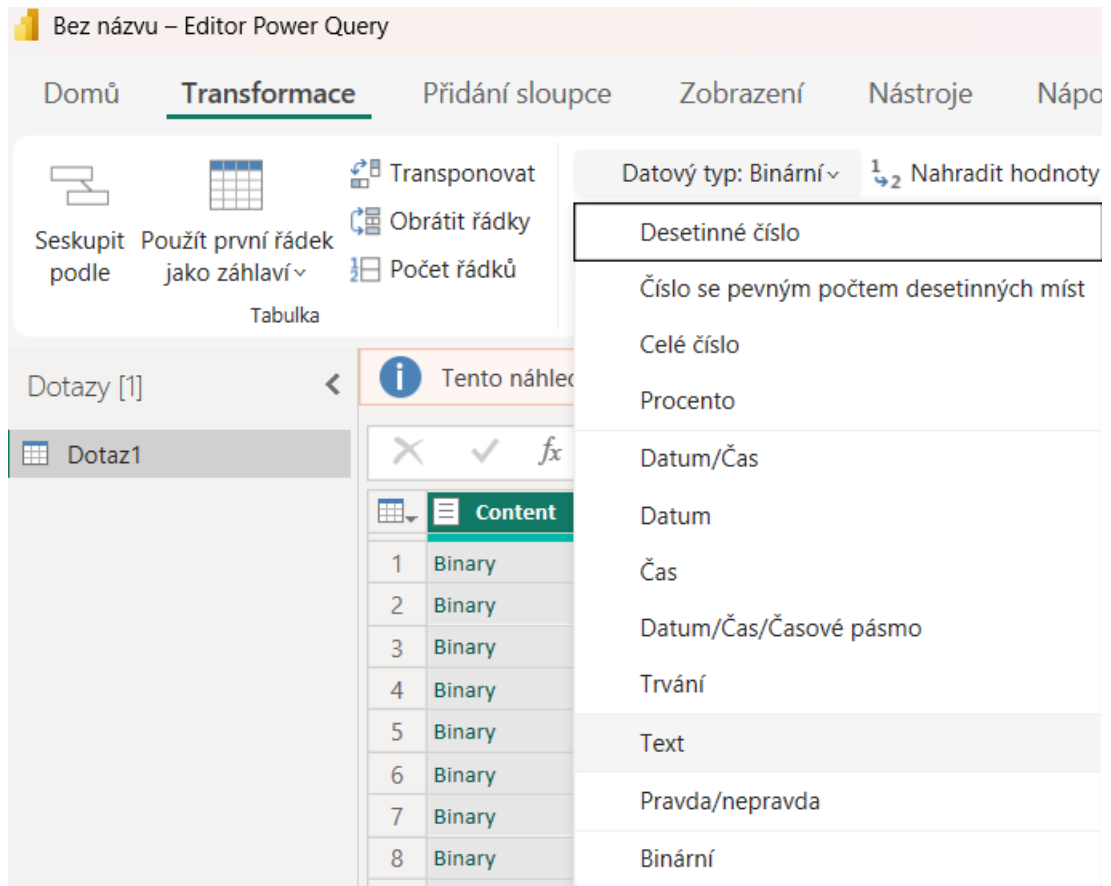
Obrázek 13 Načtená data v binárním formátu (Power BI, 2025)

2.7.4 Transformace dat v Power Query

Po navázání spojení mezi Power BI a kontejnerem **bigdata** se v uživatelském rozhraní zobrazil seznam všech souborů uložených v Azure Blob Storage. Tyto soubory byly automaticky načteny jako binární objekty, což odpovídá standardnímu chování Power BI při práci s daty uloženými v cloudu. MICROSOFT LEARN (2025c) vysvětluje, že binární formát je výhodný z hlediska výkonu, ale pro analytické zpracování je nutné tato data převést zpět do čitelného formátu.

Prvním krokem bylo kliknutí na tlačítko Transformovat data, jak je znázorněno na obrázku č. 13. Tím se otevřel nástroj Power Query, který umožňuje detailní práci s daty. Po

otevření Power Query bylo nutné převést data z binárního formátu na textový. To bylo provedeno pomocí rozbalovací nabídky **Datový typ: Binární**, kde byla zvolena možnost **Text**, jak ukazuje obrázek č. 14. Tento krok byl zásadní, protože bez převodu by nebylo možné s obsahem souborů dále pracovat.



Obrázek 14 Převod binárních dat na text (Power BI, 2025)

2.7.5 Zpřístupnění dat pro analýzu v Power BI

Po provedení všech transformací v Power Query a načtení upravených dat do datového modelu Power BI bylo možné s daty dále pracovat plnohodnotně a efektivně. Původní vstupy ve formě desítek samostatných textových souborů byly sloučeny do jedné přehledné tabulky o více než 230 milionech řádků, jak ukazuje obrázek č. 15.

Tato datová struktura představuje vhodný základ pro analytické zpracování. Podle MICROSOFT LEARN (2025a; 2025b) je tento způsob práce doporučován zejména v případech, kdy je potřeba kombinovat rozsáhlé datové sady z různých zdrojů a dále s nimi pracovat pomocí pokročilých nástrojů typu Power BI.

Dokončení tohoto kroku byl významný pokrok, protože nyní bylo možné využít silné stránky Power BI, tedy datovou analytiku, vizualizaci a reportování bez technických omezení, která původně bránila práci s daty kvůli jejich objemu a formátu.

Zdroj.Název	WK_M	MO	KNR_7	SEK	SEKVD_ID	CDILU	Mnozství
KVA (10).txt	33	PS7	370070	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	370107	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	370111	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	370118	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	370512	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	371491	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	371922	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	371939	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	371966	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1921134	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1921251	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1941421	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1941437	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1941473	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1942011	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1942033	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1952233	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1952301	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1952396	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1952438	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1962761	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1962784	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1962820	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	1962870	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	2113745	S	S78A	57H863218 WZ	1
KVA (10).txt	33	PS7	2116002	S	S78A	57H863218 WZ	1

Tabulka: Dotaz1 (řádky: 232 542 955)

Obrázek 15 Výsledná tabulka dat (Power BI, 2025)

2.7.6 Automatizovaná aktualizace dat v Power BI

Další významnou výhodou tohoto řešení je automatizovaná aktualizace dat v Power BI. Vzhledem k tomu, že Power BI je přímo napojeno na Azure Blob Storage prostřednictvím trvalé URL adresy, není nutné při každém doplnění nových souborů znovu celý proces načítání a transformace opakovat. Při každém obnovení datového modelu v Power BI systém automaticky načte aktuální obsah kontejneru **bigdata**, včetně nově přidaných souborů.

To znamená, že zaměstnanci ve společnosti ŠKODA AUTO mohou jednoduše nahrát nové .txt soubory přímo do kontejneru, a data se následně po spuštění aktualizace v Power BI

automaticky zpracují a začlení do analytického modelu. Tím je zajištěna kontinuální synchronizace mezi uloženými daty a reporty bez nutnosti ručního zásahu analytika.

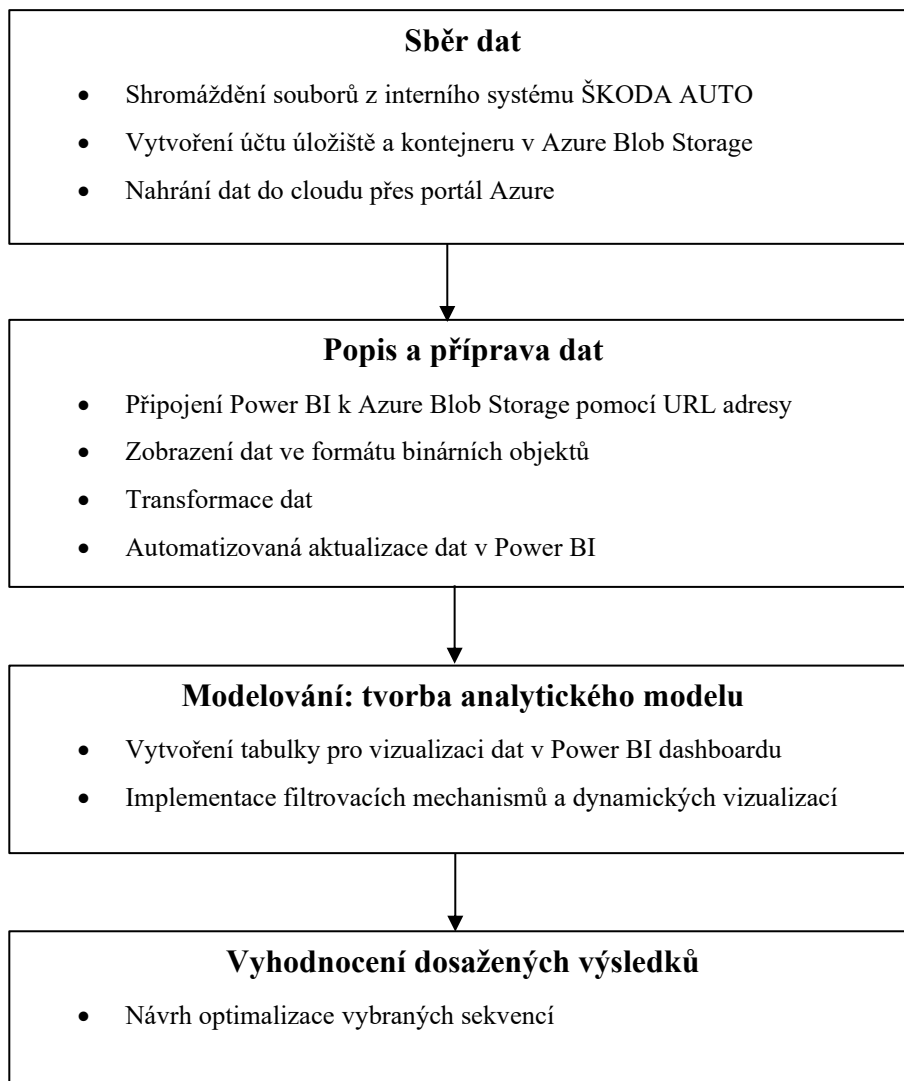
Podle MICROSOFT LEARN (2025b) představuje tento přístup doporučený způsob práce pro projekty, které vyžadují pravidelný sběr a zpracování velkého množství dat s minimálními nároky na správu.

3 NÁVRH NA OPTIMALIZACI VYBRANÝCH SEKVENCÍ

V této kapitole bude analyzován vzorek reálných dat ze společnosti ŠKODA AUTO a.s. s cílem identifikovat díly s nízkým procentuálním využitím v jednotlivých sekvencích vychystávání. Konzultant ze ŠKODA AUTO a. s. projevil zájem o analýzu právě těch dílů, které se v rámci procesu vychystávání vyskytují nejméně často. Identifikace těchto dílů by měla přispět ke strategickému rozhodování o jejich případném vyřazení ze sortimentu nebo úpravě způsobu jejich skladování. Takový krok by mohl vést ke efektivnějšímu využití skladových kapacit a celkové úspoře místa, neboť méně využívané položky zůstávají ve skladu často neúměrně dlouhou dobu bez pohybu.

Součástí této kapitoly bude také návrh konkrétních opatření k optimalizaci vybraných sekvencí. Navržená opatření budou zahrnovat například úpravu balicích jednotek nebo návrhy na redukci sortimentu prostřednictvím sloučení podobných položek. Tyto návrhy budou vycházet z reálných dat a budou směřovat k zavedení opatření s praktickým dopadem na zvýšení efektivity vnitřní logistiky.

K realizaci analýzy a vizualizaci výstupů bude využit nástroj Power BI, který umožňuje efektivní práci s rozsáhlými datovými sadami a poskytuje přehledné grafické výstupy pro snadnou interpretaci výsledků. Jednotlivé kroky postupu zpracování dat jsou znázorněny na obrázku č. 16.



Obrázek 16 Návrh tvorby modelu (autor)

První dvě části modelu z obrázku č. 16 byly popsány v předešlé kapitole. Jedná se o sběr dat a následně jejich popis a přípravu. Nyní bude podrobně rozebrána tvorba analytického modelu a samotná analýza vybraných dat.

Tabulka s daty obsahuje celkem **241 sekvenčních ID**, tedy různé sekvence, ve kterých se nachází 4 777 dílů. Některé z těchto dílů se od sebe odlišují pouze drobnými detaily. Tyto díly mají odlišné poslední znaky v označení.

V této práci budou dále podrobně analyzovány tři specifické sekvence: **S19B**, **S39A** a **S39B**. Cílem této kapitoly je identifikovat díly, které mají malé procentuální zastoupení při vychystávání.

3.1 Význam nízkého procentuálního využití

Nízké procentuální zastoupení některých dílů ve vychystávání může být ovlivněno různými faktory, které mají přímý dopad na logistiku, skladové hospodářství a výrobní procesy.

Jedním z hlavních důvodů je samotná poptávka – některé varianty dílů mohou být méně žádané kvůli preferencím zákazníků nebo specifickým konfiguracím vozidel. Na využití dílů může mít vliv i sezónnost, kdy se v určitých obdobích roku mění struktura objednávek, což ovlivňuje frekvenci jejich vychystávání. V některých případech mohou být méně využívané díly nahrazovány jinými variantami, které lépe odpovídají současným požadavkům trhu nebo zjednodušují výrobní a logistické procesy.

Dlouhodobé skladování těchto dílů přináší několik zásadních výzev. Každý metr skladovacího prostoru je cenný, a proto udržování méně využívaných dílů zbytečně navyšuje náklady na skladování. Čím déle jsou díly uskladněny, tím větší je riziko jejich zastarávání, což může vést k poškození. Z hlediska efektivity vychystávání mohou tyto díly představovat problém. Pokud se vychystávají jen zřídka, může být jejich manipulace složitější a časově náročnější, což zpomaluje celý proces.

Z těchto důvodů je klíčové analyzovat díly s nízkým využitím a rozhodnout, zda je jejich skladování a využívání nadále efektivní. V případě dílů, které mají extrémně nízkou četnost vychystávání, může být vhodné zvážit jejich vyřazení nebo přechod na jiný způsob distribuce, například objednávání podle aktuální potřeby namísto jejich dlouhodobého skladování.

3.2 Návrh na optimalizaci sekvence S19B

Tato kapitola se bude zabývat návrhem na optimalizaci výše zmíněné sekvence. Sekvence S19B se vztahuje k levému bočnímu sklu a obsahuje pět základních dílů, které se od sebe liší materiálem, úpravou povrchu a estetickými prvky (např. tónování, chromové či gumové lemování).

3.2.1 Analýza sekvence S19B

Zvolená sekvence byla analyzována kvůli potřebě identifikovat díly s nízkým procentuálním zastoupením ve vychystávání, což může mít přímý dopad na efektivitu skladování a celkovou logistiku. V této sekvenci se nachází 5 základních dílů, které jsou zobrazeny v tabulce č. 1.

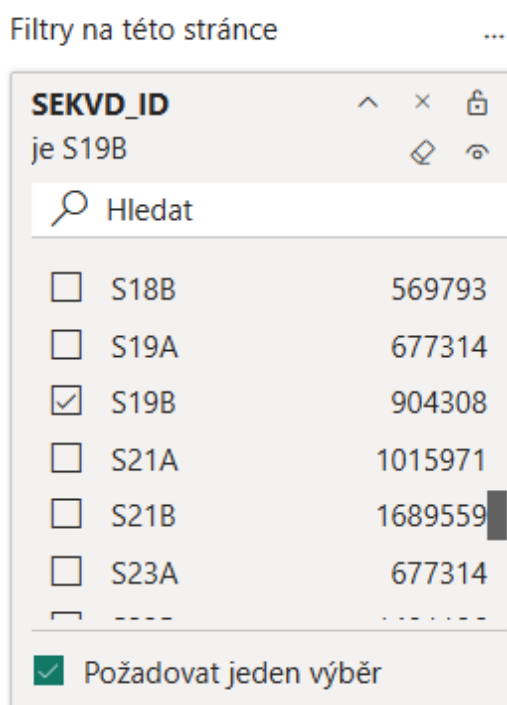
Tabulka 1 Čísla dílů levého bočního skla v sekvenci S19B

Číslo dílu	Popis
57A845297M5AP	Tónované sklo, guma
57A845297N5AP	Tmavé sklo, guma
57A845297PJV1	Tónované sklo, chrom
57A845297QJV1	Tmavé sklo, chrom
57A845297R041	Tmavé sklo, černý lesk

Zdroj: autor

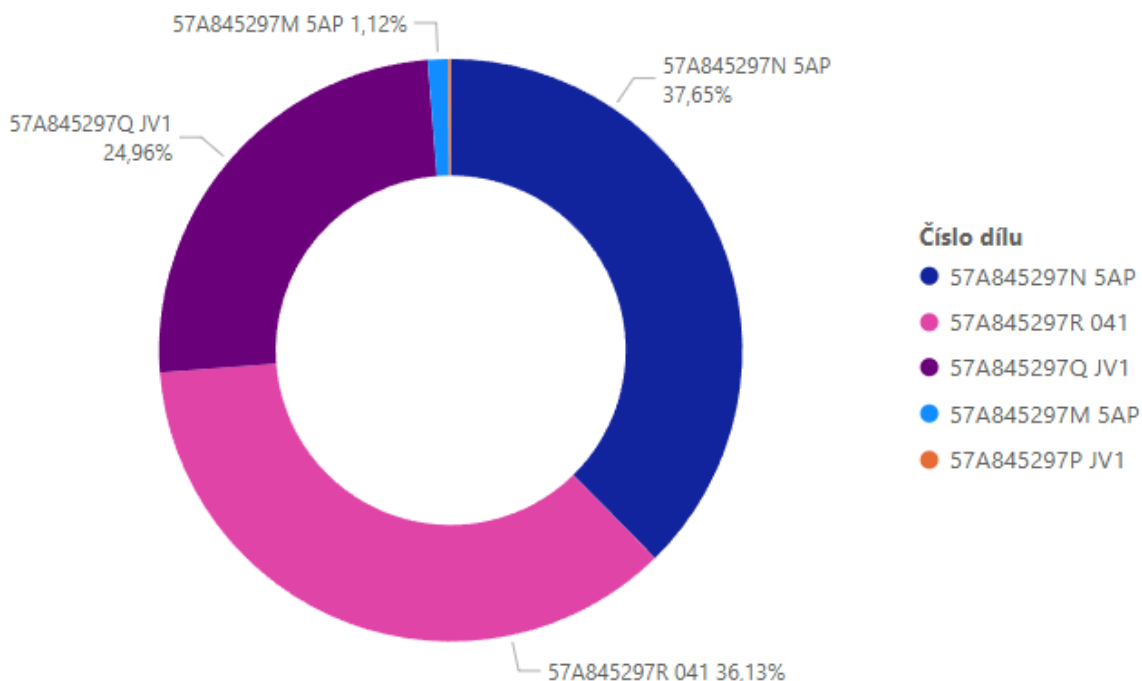
Pro detailnější zkoumání byla provedena analýza pomocí filtrovacích mechanismů a dynamických vizualizací v Power BI. Tyto nástroje umožní identifikovat vzorce ve vychystávání jednotlivých dílů a odhalit případné nesrovnalosti či neefektivitu v procesu. Díky aplikaci různých filtrů bude možné zkoumat zastoupení jednotlivých variant bočního skla a jejich četnost v sekvencích. Dynamické vizualizace pak pomohou zobrazit vývoj vychystávání a umožní snadnější interpretaci dat.

Pomocí filtrovacích mechanismů v Power BI byla vybrána sekvence S19B a dále výše uvedená čísla dílů, jelikož díly v sekvencích obsahují nejen hlavní díly, ale mohou také obsahovat spojovací materiály jako šrouby apod. Na obrázku č. 17 je zobrazen výběr zvolené sekvence. Tímto způsobem je možné vyfiltrovat jakoukoliv sekvenci, která bude potřeba zjišťovat.



Obrázek 17 Filtr pro požadovanou sekvenci (Power BI, 2025)

Graf na obrázku č. 18 znázorňuje procentuální zastoupení jednotlivých dílů v sekvenci S19B na základě jejich vychystávání ve výrobním procesu.



Obrázek 18 Graf procentuálního zastoupení vychystávání dílů v sekvenci S19B (Power BI, 2025)

Největší podíl má díl **57A845297N 5AP**, tedy tmavé sklo s gumou, které tvoří 37,65 % z celkového počtu vychystaných dílů. Následuje díl **57A845297R 041**, tmavé sklo s černým leskem, jenž představuje 36,13 %. Díl **57A845297Q JV1**, neboli tmavé sklo s chromem je zastoupeno ve 24,96 % případech. Naproti tomu díly **57A845297M 5AP** (1,12 %) a **57A845297P JV1** (0,14 %) jsou zastoupeny pouze okrajově. Klasické tabulkové zobrazení je znázorněno v tabulce č. 2.

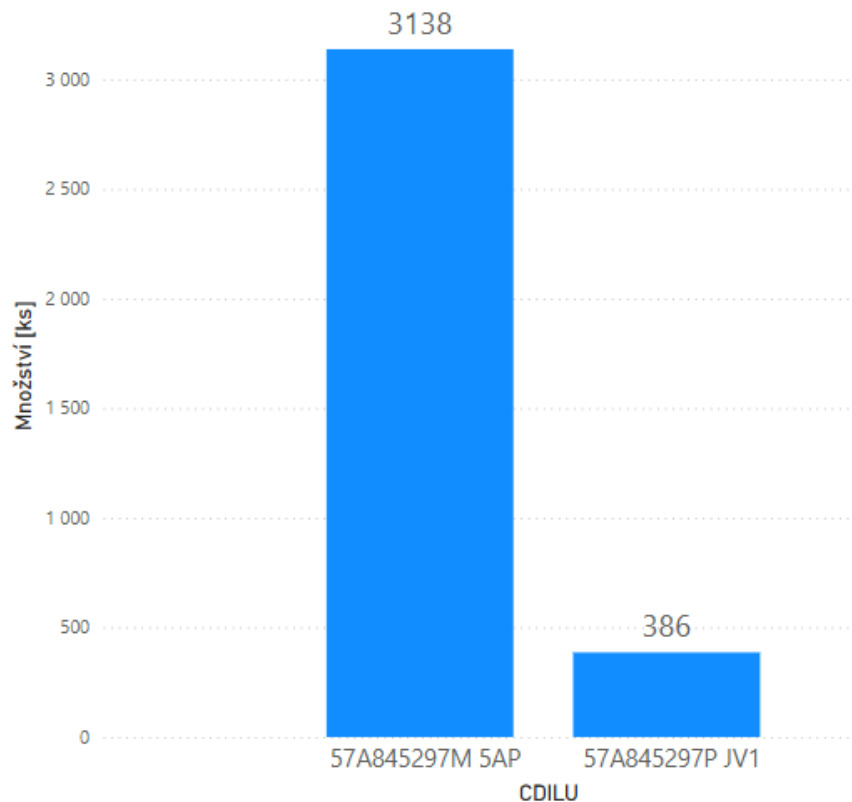
Tabulka 2 Procentuální vychystávání dílů v sekvenci S19B

SEKVD_ID	CDILU	ZASTOUPENÍ V %
S19B	57A845297N 5AP	37,65 %
S19B	57A845297R 041	36,13 %
S19B	57A845297Q JV1	24,96 %
S19B	57A845297M 5AP	1,12 %
S19B	57A845297P JV1	0,14 %
Celkem		100,00 %

Zdroj: autor

Z těchto dat je patrné, že některé varianty bočního skla jsou výrazně preferované, zatímco jiné mají velmi nízké využití. To může být podnětem k optimalizaci skladových zásob nebo revizi nabídky dílů, které by mohly být případně vyřazeny z procesu.

V následujícím grafu na obrázku č. 19 jsou zobrazeny pouze okrajově vychystávané výše zmíněné díly **57A845297M 5AP** a **57A845297P JV1**. Z grafu je patrné, že prvního dílu bylo vychystáno 3138 ks a druhého dílu pouze 386. Jedná se o vychystávání těchto dílů za období od 1. června 2024 do 31. prosince 2024 neboli data za 213 dní.



Obrázek 19 Počet okrajově vychystávaných dílů v sekvenci S19B (Power BI, 2025)

S použitím vzorce 1 bude vypočteno průměrné vychystávání materiálů za 1 pracovní den.

$$Q = \frac{q}{\text{počet dní}} \text{ [ks/den]} \quad (1)$$

kde:

Q ... průměrný denní počet vychystaných kusů [ks/den]

q ... počet vychystaných kusů za celé období [ks]

počet dní ... počet dní, za který byla poskytnutá data [213 dní]

Na základě výpočtu provedeného dle vzorce 1 bylo zjištěno, že průměrný denní počet vychystaných kusů dílu **57A845297M 5AP** (tónované sklo s gumou) činí pouze 14,73 kusů.

U druhého sledovaného dílu, konkrétně **57A845297P JV1** (tónované sklo s chromem), je tento průměr ještě výrazně nižší, a to pouze 1,81 kusů denně. Oba tyto díly jsou skladovány na paletách, přičemž **kapacita jedné palety je 48 kusů**.

Z výše uvedeného vyplývá, že v případě dílu **57A845297M 5AP** odpovídá denní spotřeba přibližně **0,3 palety**. Při přepočtu na měsíc se jedná o přibližně 9 palet za měsíc. U druhého dílu, **57A845297P JV1**, je situace ještě výrazněji odlišná. Zde denní spotřeba činí pouze **0,04 palety**, což odpovídá přibližně 1 paletě za měsíc.

Tyto hodnoty jsou důležité pro hodnocení efektivity využití skladové plochy. Dlouhá doba, po kterou jsou jednotlivé palety v systému naskladněny bez pohybu, má přímý vliv na obrátkovost zásob a efektivitu skladu. Vzhledem k velmi nízké obrátkovosti těchto dvou položek může být vhodné zvážit jejich přebalení do menších logistických jednotek, případně upravit objednávkové množství či četnost doplňování, aby se snížil podíl nevyužité skladové kapacity a zároveň se zajistila dostatečná dostupnost materiálu pro výrobu.

3.2.2 Přebalení dílů do menších logistických jednotek

Jedním z praktických opatření, jak zvýšit efektivitu skladového hospodářství v souvislosti s nízkofrekvenčními díly v sekvenci S19B, je přebalení těchto dílů do menších logistických jednotek. V současné době jsou všechny varianty levého bočního skla dodávány a skladovány na standardních paletách s kapacitou 48 kusů. Tento způsob balení je z logistického hlediska efektivní zejména pro díly s vysokou obrátkovostí, u nichž dochází k pravidelnému doplňování a spotřebě v krátkých časových intervalech.

V případě dílů **57A845297M 5AP** a **57A845297P JV1**, jejichž denní vychystávání činí v průměru pouze 14,73 kusů, resp. 1,81 kusů, je však využití plných palet z pohledu efektivity značně problematické. V praxi to znamená, že zásoba uložená na jedné paletě je ve skladu přítomna výrazně delší dobu, než je běžné u ostatních komponent. To vede k nevyužití skladové kapacity, zbytečně zabranému prostoru a snižování celkové obrátkovosti zásob.

Návrhem je, aby byly tyto konkrétní díly přebalovány do menších jednotek, například do polovičních palet s kapacitou 24 kusů nebo čtvrtinových palet s kapacitou 12 kusů. Takové řešení lépe odpovídá reálnému tempu spotřeby a zároveň usnadňuje manipulaci i skladování. Menší jednotky je možné flexibilněji zařazovat do skladového systému, přesouvat v rámci výrobního toku a rychleji naskladnit nebo vyskladnit bez nutnosti manipulace s nadbytečným množstvím zboží.

Tento přístup přináší několik konkrétních výhod. V první řadě dojde ke zvýšení efektivity využití skladové plochy, protože skladovací místa budou lépe přizpůsobena skutečné

potřebě daného dílu. Dále se zlepší přehlednost a řízení zásob, neboť menší balicí jednotky umožní přesnější kontrolu a sledování toku materiálu. Navíc menší množství na skladě přispívá k rychlejšímu obratu zásob, což je v souladu s principy štíhlé logistiky a snižování plýtvání (tzv. lean warehousing). Z hlediska implementace takového opatření je nutné prověřit technické možnosti přebalení u dodavatele, případně nastavit tento proces přímo ve skladu společnosti ŠKODA AUTO. Důležité je rovněž vyhodnotit dopad na náklady spojené s balením a manipulací, které by měly být kompenzovány úsporami na skladové ploše a zefektivněním logistiky. Přebalení nízkofrekvenčních dílů do menších logistických jednotek by mohl být jednoduchý a zároveň účinný krok, jak zlepšit tok materiálu, snížit náklady a zvýšit flexibilitu interní logistiky bez zásahu do sortimentu.

3.3 Návrh na optimalizaci sekvence S39A a S39B

Tato kapitola se zaměřuje na sekvence S39A a S39B, které se týkají vychystávání volantů. Cílem je navrhnout možnosti jejich optimalizace s ohledem na efektivitu a přehlednost v rámci logistického procesu. Součástí kapitoly je také popis aktuálního způsobu balení volantů.

3.3.1 Balení volantů

Pro potřeby zásobování jsou volanty dodávány ve dvou odlišných typech balení, která se liší svou konstrukcí i kapacitou. Správný výběr balení je zásadní nejen pro efektivní využití skladových prostor, ale také pro zajištění plynulosti v toku materiálu směrem k montážní lince.

- **Standardní balení (kód 527705)**

Základním a preferovaným formátem je standardní balení, označované interním kódem **527705**. Toto balení je navrženo pro stabilní a předvídatelné skladování i manipulaci s volanty. V konstrukci balení jsou volanty uspořádány do dvou řad a dvou sloupců, a to ve svislé poloze. Takto poskládané díly zajišťují stabilitu při přepravě a zároveň umožňují dobrý přehled při vyskladňování.

Celková kapacita tohoto balení činí **44 kusů volantů na jednu paletu**. Tento objem je nastaven s ohledem na kompromis mezi rozměrovou efektivitou a ergonomií vychystávání. Tento typ balení je zobrazen na obrázku č. 20.

- **Náhradní balení (kódy 0006PAL / 0007PAL)**

Druhým typem je tzv. náhradní balení, označené kódy **0006PAL a 0007PAL**, které slouží jako alternativní řešení v případech, kdy standardní balení není z různých důvodů k dispozici. Toto balení má odlišnou konstrukci, je kartonové a volanty jsou umístěny v šesti patrech nad sebou, přičemž v každém patře se nachází 9 kusů volantů, to je viditelné na obrázku č. 21. Celková kapacita je tedy **54 kusů na jednu paletu**, což znamená o 10 volantů více než

u standardního balení. Z hlediska objemu tak jde o prostorově efektivnější variantu, která však může být náročnější na manipulaci, a to především kvůli vyšší výšce balení a rozdílnému rozmístění dílů.

Z logistického hlediska je důležité, že tato balení mohou ovlivnit kapacitu skladovacích pozic, protože zabírají více skladovacího prostoru, než standardní balení.



Obrázek 20 Standardní balení volantů (ŠKODA AUTO, 2025)

Tabulka č. 3 obsahuje přehled volantů určených pro model **Škoda Kodiaq**, které jsou dodávány v rámci sekvence S39A. Každý volant je identifikován unikátním číslem dílu a může být balen ve dvou různých typech balení – standardním **527705** nebo náhradním **0007PAL**. Z tabulky vyplývá, že volanty pro vozidlo ŠKODA Kodiaq jsou dodávány v obou typech balení, přičemž první čtyři díly v seznamu využívají náhradní balení 0007PAL, zatímco ostatní volanty jsou baleny ve standardním formátu 527705.



Obrázek 21 Náhradní balení volantů (ŠKODA AUTO, 2025)

3.3.2 Analýza sekvence S39A ŠKODA Kodiaq

Sekvence S39A se vztahuje k montážní lince 2, kde se montují různé typy volantů určených pro finální montáž vozidel. Na této montážní lince se jedná pouze o volanty pro vozidlo **ŠKODA Kodiaq**. Vozy Škoda Octavia, Karoq a Kodiaq využívají společné typy volantů, které jsou zaměnitelné napříč všemi těmito modely. Cílem této analýzy je podrobně zhodnotit složení této sekvence z hlediska jednotlivých dílů a jejich četnosti ve vychystávání.

Tabulka 3 Čísla dílů volantů v sekvenci S39A

Číslo dílu	Název dílu	Balení	Sekvenční ID	Model
5E3419093DAKKI	VOLANT	0007PAL	S39A	Kodiaq
5E3419093DCKKI	VOLANT	0007PAL	S39A	Kodiaq
5E3419093DJKJI	VOLANT	0007PAL	S39A	Kodiaq
5E3419093DLKJI	VOLANT	0007PAL	S39A	Kodiaq
5E3419093DSKKI	VOLANT	527705	S39A	Kodiaq
5E3419093EAKKI	VOLANT	527705	S39A	Kodiaq
5E3419093ECKIZ	VOLANT	527705	S39A	Kodiaq
5E3419093ECKJI	VOLANT	527705	S39A	Kodiaq
5E3419093EEKIZ	VOLANT	527705	S39A	Kodiaq
5E3419093EEKJI	VOLANT	527705	S39A	Kodiaq
5E3419093FNKKI	VOLANT	527705	S39A	Kodiaq
5E3419093FQKKI	VOLANT	527705	S39A	Kodiaq

5E3419093FSKIZ	VOLANT	527705	S39A	Kodiaq
5E3419093FSKJI	VOLANT	527705	S39A	Kodiaq
5E3419093GAKIZ	VOLANT	527705	S39A	Kodiaq
5E3419093GAKJI	VOLANT	527705	S39A	Kodiaq

Zdroj: autor (vypracováno dle interních materiálů ŠKODA AUTO)

Analýza procentního zastoupení jednotlivých dílů v sekvenci S39A v Power BI probíhá pomocí filtračních mechanismů, které umožňují detailní segmentaci dat a jejich vizualizaci. Vzhledem k tomu, že data jsou již importovaná do Power BI, využívám dostupné funkce pro filtrování a dynamické zobrazování podílů jednotlivých dílů na celkovém množství volantů v dané sekvenci.

Prvním krokem je aplikace filtrů, které umožňují zúžení analýzy na relevantní subset dat. Mezi klíčové filtry patří čísla dílů a samotná sekvence. Díky těmto filtrům lze interaktivně přepínat mezi sekvencemi a sledovat, jak se mění procentuální zastoupení jednotlivých typů volantů a umožňuje oddělit data pro S39A a S39B.

Po aplikaci filtrů je procentní zastoupení jednotlivých dílů vizualizováno v tabulkové podobě a je zobrazeno v tabulce č.4.

Tabulka 4 Procentuální vychystávání dílů v sekvenci S39A

SEKVD_ID	CDILU	ZASTOUPENÍ V %
S39A	5E3419093DSKKI	17,16%
S39A	5E3419093ECKJI	13,77%
S39A	5E3419093FSKJI	12,55%
S39A	5E3419093DAKKI	12,54%
S39A	5E3419093EAKKI	11,16%
S39A	5E3419093FQKKI	6,59%
S39A	5E3419093FNKKI	6,52%
S39A	5E3419093EEKJI	4,96%
S39A	5E3419093DJKJI	4,24%
S39A	5E3419093DCKKI	3,87%
S39A	5E3419093GAKJI	3,19%
S39A	5E3419093DLKJI	2,05%
S39A	5E3419093FSKIZ	1,24%
S39A	5E3419093GAKIZ	0,13%
S39A	5E3419093ECKIZ	0,02%
S39A	5E3419093EEKIZ	0,00%
Celkem		100,00%

Zdroj: autor

Tabulka ukazuje procentuální zastoupení jednotlivých volantů v sekvenci **S39A** pro model **Škoda Kodiaq**. Každý řádek reprezentuje konkrétní typ volantu, identifikovaný svým číslem dílu, a jeho podíl na celkovém objemu vychystávaných volantů.

Nejčastěji zastoupeným volantem v této sekvenci je díl **5E3419093DSKKI**, který tvoří **17,16 %** celkového objemu. Další významné zastoupení mají volanty **5E3419093ECKJI** (**13,77 %**) a **5E3419093FSKJI** (**12,55 %**). Naopak některé díly mají **0 % zastoupení**, což znamená, že v analyzovaném období nebyly v rámci této sekvence skoro vůbec využity.

Díly s menším než **3% zastoupením**:

- **5E3419093DLKJI**
- **5E3419093FSKIZ**
- **5E3419093GAKIZ**
- **5E3419093ECKIZ**
- **5E3419093EEKIZ**

Z analýzy vyplývá, že u volantů s procentuálním zastoupením **pod 3 %** by mělo být zváženo, zda je ekonomicky efektivní tyto díly dále nabízet konečnému zákazníkovi. Jejich nízké zastoupení naznačuje, že se využívají pouze zřídka, což může způsobovat komplikace v logistice a skladování. Zejména díly s nulovým zastoupením, jako je **5E3419093EEKIZ**, je vhodné podrobit detailnější revizi a posoudit jejich další využití v rámci výrobního procesu. Optimalizace portfolia dílů by mohla vést ke snížení nákladů spojených s jejich dodávkou a skladováním.

Pokud by se přistoupilo k rozhodnutí vyřadit z nabídky díly s procentuálním zastoupením nižším než 3 %, znamenalo by to nejen zjednodušení sortimentu, ale také výraznou úsporu skladovacího prostoru. Ve výrobním a logistickém procesu je důležité udržovat v systému pouze ty položky, které mají reálné a opakované využití. Každý typ volantu vyžaduje zvláštní manipulaci, skladovací lokaci a evidenci v systému. Pokud se ale tyto díly vyskytují pouze ve zcela minimálním množství, jejich přínos neodpovídá vynaloženým nákladům na skladování, správu a případné dodání.

V tomto konkrétním případě se jedná o pět dílů, jejichž procentuální zastoupení v rámci sekvence **S39A** klesá pod hranici 3 %. Tyto díly mají marginální využití, v některých případech prakticky nulové. Udržování těchto volantů ve skladových zásobách znamená, že zabírají místo, které by mohlo být efektivně využito pro více frekventované a žádané díly. Zároveň platí, že čím širší sortiment výrobků je nutné řídit, tím náročnější je proces skladové evidence,

plánování výroby a samotná logistika dodávek. Odstraněním těchto málo využívaných dílů z nabídky by bylo možné:

- redukovat počet potřebných skladovacích pozic,
- snížit chybovost při vychystávání a inventurách,
- a soustředit pozornost na zjednodušení portfolia dílů.

Z pohledu interní logistiky a plánování výroby takové rozhodnutí přispívá k celkové optimalizaci procesů, což může mít přímý dopad na snížení provozních nákladů a zrychlení toku materiálu skrze celý závod.

3.3.3 Návrh na optimalizaci sekvence S39A

Analýza dat ze sekvence S39A, která zahrnuje volanty určené pro model ŠKODA Kodiaq, odhalila nerovnoměrné rozložení podílů jednotlivých dílů na celkovém vychystávání. Z celkového počtu sledovaných položek vykazuje pět dílů zastoupení nižší než 3 %, přičemž jeden z nich byl v analyzovaném období vychystán minimálně a v tabulce je jeho hodnota zastoupení 0 %. Konkrétně se jedná o díly **5E3419093DLKJI**, **5E3419093FSKIZ**, **5E3419093GAKIZ**, **5E3419093ECKIZ** a **5E3419093EEKIZ**. Tato zjištění ukazují, že se jedná o málo využívané komponenty, které mohou z logistického pohledu představovat zbytečné zatížení systému.

Každý typ volantu musí být samostatně evidován, skladován a připravován k vychystávání. Pokud však některé z nich vykazují jen okrajové využití, jejich přítomnost v aktivním portfoliu přináší nepřiměřené nároky na skladovou plochu i interní operace. V takových případech je namístě uvažovat o redukci sortimentu formou vyřazení těchto dílů, nebo jejich sjednocení s podobnými typy, které se ve výrobním procesu vyskytují častěji.

Například volant **5E3419093ECKIZ** by mohl být sloučen s dílem **5E3419093ECKJI**, neboť se pravděpodobně jedná o varianty s drobnými rozdíly v povrchové úpravě nebo dekoračních prvcích. Obdobná situace platí také pro dvojici **5E3419093GAKIZ** a **5E3419093GAKJI**, kde by sjednocení mohlo vést ke zjednodušení vychystávacího procesu, aniž by to mělo vliv na kvalitu nebo funkčnost výsledného výrobku. V případě dílu **5E3419093EEKIZ**, který byl v daném období vychystáván pouze čtyřikrát, je na místě zvážit jeho úplné vyřazení z nabídky.

Zavedení těchto opatření by vedlo k celkovému zjednodušení portfolia, čímž by se snížil počet evidovaných položek a uvolnila se skladová kapacita. Zároveň by se zlepšilo plánování zásobování, protože menší variabilita přispívá k vyšší přehlednosti a plynulejšímu toku materiálu.

Tento návrh lze vnímat jako krok směrem k efektivnější a přehlednější logistice, který naplňuje principy štíhlého řízení. Eliminací málo používaných položek se nejen zjednoduší interní procesy, ale současně dojde k úspoře času, místa i nákladů bez zásadního dopadu na zákaznickou variabilitu nebo kvalitu finálního produktu.

3.3.4 Analýza sekvence S39B SEAT Ateca

Tato sekvence se naopak montuje na montážní lince 1 se jedná o volanty k vozidlům ŠKODA Octavia, Karoq a SEAT Ateca. U vozidla Seat Ateca se používají specifické typy volantů, které nejsou sdíleny s ostatními modely. Naopak vozy Škoda Octavia, Karoq a Kodiaq využívají společné typy volantů, které jsou zaměnitelné napříč těmito modely.

Zde se analýza zaměří pouze na vozidlo **SEAT Ateca**. V tabulce č. 5 se nachází díly volantu pro vozidlo **SEAT Ateca**. Počet volantů pro tento typ vozidla je 22. Volanty pro tento typ vozidla jsou baleny pouze v náhradním balení **0006PAL**.

Tabulka 5 Čísla dílů volantů v sekvenci S39B pro SEAT Ateca

Číslo dílu	Název dílu	Balení	Sekvenční ID	Model
5FA419091ADWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091AEWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091DNHIG	VOLANT	0006PAL	S39B	Ateca
5FA419091DPHIG	VOLANT	0006PAL	S39B	Ateca
5FA419091EEWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091EFWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091EMWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091ENWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091ETWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091FBWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091FDWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091FEWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091FFWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091FGWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091HWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091JBWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091JCWVY	VOLANT	0006PAL	S39B	Ateca
5FA419091JDHIG	VOLANT	0006PAL	S39B	Ateca
5FA419091JEHIG	VOLANT	0006PAL	S39B	Ateca
5FA419091PWVY	VOLANT	0006PAL	S39B	Ateca
5FF419091WVY	VOLANT	0006PAL	S39B	Ateca
5FF419091AWVY	VOLANT	0006PAL	S39B	Ateca

Zdroj: autor (vypracované dle interních materiálů ŠKODA AUTO)

Analýza procentního zastoupení jednotlivých dílů v sekvenci S39B probíhala obdobným způsobem jako u sekvence S39A. V Power BI byly aplikovány žádoucí filtrační mechanismy, které umožnily segmentaci dat podle čísla dílu a sekvence. Pomocí těchto nástrojů bylo možné vizuálně porovnat podíly jednotlivých typů volantů v rámci konkrétní sekvence, v tomto případě S39B, a oddělit tak data určená pro model **SEAT Alteca** od ostatních.

Po analýze datového balíčku ze ŠKODA AUTO bylo zjištěno procentuální zastoupení jednotlivých dílů volantů pro vozidlo SEAT Alteca, které je zobrazeno v tabulce č. 6.

Tabulka 6 Procentuální vychystávání dílů pro SEAT Alteca

SEKVD_ID	CDILU	ZASTOUPENÍ V %
S39B	5FA419091FDWV	16,48%
S39B	5FA419091FEWV	13,03%
S39B	5FA419091DNHIG	8,23%
S39B	5FA419091FGWV	6,78%
S39B	5FA419091EEWV	6,44%
S39B	5FA419091DPHIG	6,41%
S39B	5FA419091EFWV	6,35%
S39B	5FA419091ADWV	6,19%
S39B	5FF419091 WV	4,72%
S39B	5FA419091JCWV	3,53%
S39B	5FA419091FBWV	3,11%
S39B	5FA419091ETWV	2,59%
S39B	5FA419091JEHIG	2,58%
S39B	5FA419091JDHIG	2,40%
S39B	5FA419091FFWV	2,16%
S39B	5FA419091JBWV	2,15%
S39B	5FA419091EMWV	1,81%
S39B	5FF419091A WV	1,44%
S39B	5FA419091ENWV	1,41%
S39B	5FA419091H WV	1,31%
S39B	5FA419091AEWV	0,73%
S39B	5FA419091P WV	0,14%
Celkem		100,00%

Zdroj: autor

Z tabulky je patrné, že procentuální zastoupení méně než 3 % se jedná u 11 dílů volantů, což je polovina celkového množství volantů pro tento typ vozidla.

3.3.5 Návrh redukce nízkofrekvenčních dílů pro volanty SEAT Alteca S39B

Na základě provedené analýzy sekvenčního vychystávání v závodě ŠKODA AUTO a.s. bylo identifikováno celkem jedenáct typů volantů, jejichž zastoupení v celkovém objemu

nepřesahuje 3 %. Tyto varianty lze označit jako nízkofrekvenční díly, jelikož se vychystávají pouze výjimečně. Přesto však jejich existence výrazně zatěžuje logistické procesy, protože každá varianta vyžaduje samostatnou evidenci a vlastní skladovou pozici.

Vzhledem k těmto okolnostem je žádoucí zvážit redukci počtu těchto dílů prostřednictvím sjednocení technicky či vzhledově podobných variant. Cílem není omezit zákaznické možnosti, ale racionálně zjednodušit interní logistické toky při zachování estetických i funkčních nároků na jednotlivý díl. Příkladem takového postupu může být sloučení variant **5FA419091JWVV**, **5FA419091EMWVV** a **5FA419091EWVV**, které se liší pouze v detailech, jako je typ prošívání nebo povrchová úprava. Jelikož tyto rozdíly nemají zásadní vliv na komfort ani bezpečnost, je možné uvažovat o zavedení jedné sjednocené univerzální varianty, která pokryje potřeby více konfigurací vozidel.

Podobně lze přistupovat k volantům s kódy **5FA419091AEWVV** a **5FA419091PWVV**, jejichž zastoupení je zcela marginální (0,73 % a 0,14 %). U těchto položek lze uvažovat o jejich vyřazení z nabídky, případně jejich nahrazení běžněji používaným typem. Výhodou je, že i minimální redukce počtu položek se v závodě rychle projeví na vyšší efektivitě procesů.

Výhody tohoto opatření jsou zřejmé. V první řadě by došlo k zjednodušení procesu vychystávání, protože by se snížil počet unikátních položek, které musí pracovníci nebo automatické systémy identifikovat, vychystat a doručit k výrobní lince. To přispívá ke snížení chybovosti a zrychlení operací. Zároveň by klesly nároky na skladové prostory, což by vedlo ke snížení provozních nákladů spojených se skladováním a manipulací s materiálem. Významnou výhodou je i snazší plánování výroby a zásobování, protože menší variabilita komponentů zjednodušuje předpovědi spotřeby, minimalizuje riziko výpadků a zajišťuje plynulejší tok materiálu.

Z dlouhodobého pohledu přináší redukce nízkofrekvenčních dílů i strategické výhody – přispívá k větší standardizaci sortimentu, usnadňuje zavádění automatizace a zvyšuje odolnost procesů vůči neočekávaným výkyvům v dodávkách. Z hlediska zákazníka lze navrženou změnu podpořit vhodným marketingovým vysvětlením, neboť rozdíly mezi variantami jsou často vnímatelné pouze minimálně a zákazník jimi není zásadně ovlivněn.

Z těchto důvodů lze návrh na redukci nízkofrekvenčních dílů považovat za opatření, které přináší synergii mezi logistikou, výrobou i ekonomickými cíli společnosti. Tento přístup navazuje na moderní trendy ve štíhlé logistice a podporuje datově řízená rozhodnutí v oblasti optimalizace vnitropodnikových procesů.

4 VYHODNOCENÍ PŘÍNOSŮ NAVRŽENÉHO OPATŘENÍ

Tato kapitola shrnuje přínosy navržených optimalizačních opatření na základě analýzy sekvencí **S19B**, **S39A** a **S39B**. Posuzuje jejich dopad na efektivitu skladového hospodářství. Návrhy byly formulovány s ohledem na reálné podmínky výroby a preferenci konzultantů společnosti ŠKODA AUTO a.s., kteří požadovali zaměření na díly s nízkým výskytem ve vychystávání.

Součástí řešení je Power BI soubor, do kterého je možné v budoucnu dohrát další datové sady a automaticky tak vytvářet nové srovnávací přehledy podle aktuální situace v závodě. Díky tomu lze jednoduše reagovat na požadavky konzultantů, například vytvořením filtrů pro další atraktivní nebo problémové sekvence. Omezením v rámci poskytnutých dat byla absence časových údajů, což neumožnilo predikce nebo sezónní analýzy. Přesto návrhy vycházejí z reálných provozních dat a reflektují konkrétní možnosti zefektivnění interní logistiky.

4.1 Zhodnocení návrhu sekvence S19B

V rámci sekvence S19B byly identifikovány dvě varianty levého bočního skla – **57A845297M5AP** (tónované sklo s gumou) a **57A845297PJV1** (tónované sklo s chromem), které se v analyzovaném období vychystávaly pouze okrajově. Jejich denní průměr vychystávání činil 14,73 kusů, resp. 1,81 kusů, přičemž obě varianty jsou baleny do palet po 48 kusech. Z hlediska využití skladové kapacity tak dochází k výraznému nepoměru mezi spotřebou a velikostí logistické jednotky, což vede k dlouhodobému blokování skladové plochy a snižování efektivity.

Na základě těchto zjištění byl navržen konkrétní krok k optimalizaci, a to přebalení nízkofrekvenčních položek do menších logistických jednotek, jako jsou poloviční nebo čtvrtinové palety. Takové řešení lépe odpovídá reálné spotřebě a umožňuje přesnější řízení zásob. Díky tomu lze snížit prostorové nároky na sklad, zlepšit obrátkovost zásob a omezit nadbytečnou manipulaci s materiálem.

Tento návrh je prakticky realizovatelný a přináší několik přímých přínosů:

- úspora skladové plochy díky efektivnějšímu přizpůsobení balení skutečné spotřebě,
- zvýšení flexibility manipulace – menší jednotky lze snadněji zařazovat a přemisťovat,
- snížení rizika nevyužitých zásob a tím i omezení interních nákladů.

Zároveň je však nutné vzít v úvahu kontext obchodní a výrobní strategie, na který upozornil odborník ze společnosti ŠKODA AUTO. Jak vyplývá z interního materiálu od

Řeháka (2022), Petr Skála upozorňuje, že tónovaná skla ve výbavě vozidel plní nejen funkční, ale i cenově-strategickou roli. Základní varianty vozidel jsou osazovány levnějšími typy tónovaných skel, zatímco za prémiové provedení SunSet zákazník připlácí. Tato cenová diferenciací odpovídá požadavkům marketingového oddělení, které usiluje o co nejnižší vstupní cenu vozidla a zároveň o možnost nabídnout placený upgrade.

Zcela odstranit tónovaná skla z produktové nabídky by tedy znamenalo narušení zavedeného obchodního modelu, a tedy nejlevnější verze vozů by musely zdražit a zároveň by došlo ke ztrátě příjmů z příplatkových prvků. Navíc existují trhy, například země Perského zálivu nebo Indie, kde je sklo typu SunSet zakázané, a použití varianty s tónovanými skly je tak nutností z hlediska legislativy.

Z výše uvedeného vyplývá, že úplné zrušení těchto položek z nabídky není reálně proveditelné, neboť by narušilo obchodní model firmy a dostupnost některých variant pro specifické trhy. Proto se jako realistický a přínosný kompromis jeví právě navržené přebalení dílů a úprava logistického režimu, nikoliv zásah do produktové skladby.

Finální návrh odpovídá principům štíhlé logistiky a je v souladu s výrobní realitou i obchodní strategií podniku. Při správném zavedení může přinést měřitelné úspory v oblasti skladování, a zároveň zachovat variabilitu výrobku, která je důležitá jak z pohledu marketingu, tak legislativních požadavků zahraničních trhů.

4.2 Zhodnocení návrhu sekvence S39A

Analýza sekvence S39A zaměřené na vychystávání volantů pro model ŠKODA Kodiaq odhalila, že pět konkrétních typů dílů (např. **5E3419093DLKJI**, **5E3419093FSKIZ**, **5E3419093ECKIZ**, **5E3419093GAKIZ** a **5E3419093EEKIZ**) má zastoupení nižší než 3 %, přičemž některé z nich nevykázaly v analyzovaném skoro žádnou aktivitu. Skladování a správa těchto položek přinášejí zbytečnou zátěž v rámci interní logistiky. Každý takový díl vyžaduje vlastní skladovací pozici, systémovou evidenci a ruční či automatizovanou manipulaci, přestože jeho využití je z provozního hlediska minimální.

Na základě těchto zjištění bylo navrženo snížení počtu sledovaných dílů prostřednictvím sloučení podobných variant nebo jejich úplného vyřazení z nabídky. Tento přístup je plně v souladu s principy štíhlé logistiky, která usiluje o zjednodušení materiálového toku, snížení variability a minimalizaci plýtvání.

Například díly **5E3419093ECKIZ** a **5E3419093ECKJI** se liší jen v drobných vizuálních prvcích, nikoliv ve funkčních vlastnostech. Stejně tak varianta **5E3419093GAKIZ** může být nahrazena častěji používaným typem **5E3419093GAKJI**, čímž by došlo ke snížení

počtu aktivních položek bez dopadu na finální produkt. Díl **5E3419093EEKIZ**, který vykazuje minimální četnost, je vhodné vyřadit, pokud pro něj neexistuje specifický zákaznický nebo legislativní požadavek.

Přínosy navrženého opatření zahrnují:

- zjednodušení vychystávacího procesu díky snížení počtu evidovaných variant,
- úsporu skladové plochy,
- nižší chybovost při inventurách,
- zvýšení přehlednosti a rychlosti plánování zásob.

Z hlediska výrobní flexibility je důležité zvážit každý zásah do sortimentu s ohledem na požadavky trhu a dostupnost náhradních variant. V tomto případě se však návrh týká především málo používaných položek, jejichž udržování v systému není ekonomicky ani provozně opodstatněné. Jejich odstranění nebo sjednocení s jinými variantami přinese rychle měřitelné provozní úspory a sníží náročnost logistických operací bez ztráty kvality či zákaznické volby.

Z pohledu dlouhodobého rozvoje podniku představuje toto opatření krok směrem ke standardizaci a stabilizaci vnitřního toku materiálu, což je nezbytné pro rozvoj digitalizace a další zvyšování efektivity procesů.

4.3 Zhodnocení návrhu sekvence S39B

Návrh optimalizace sekvence S39B vycházel z analýzy procentuálního zastoupení jednotlivých volantů, které jsou součástí vychystávacího procesu. Výsledky ukázaly, že celkem jedenáct dílů vykazuje zastoupení nižší než 3 %, přičemž některé z nich mají spotřebu zcela minimální. Jedná se tedy o nízkofrekvenční položky, které výrazně zatěžují systém skladování, vychystávání, aniž by měly odpovídající přínos.

Na základě těchto zjištění byl vytvořen návrh, jehož cílem je redukovat počet těchto dílů buď formou sjednocení podobných variant, nebo jejich vyřazením z nabídky. Například volanty **5FA419091JWVV**, **5FA419091EMWVV** a **5FA419091EWVV** se liší pouze v detailech, jako je typ prošití nebo barevné provedení, a jejich sjednocení by bylo z hlediska logistiky výhodné, aniž by mělo dopad na funkčnost nebo bezpečnost produktu. U dílů jako **5FA419091PWVV**, které se v daném období téměř neobjevily, lze uvažovat o jejich vyloučení ze sortimentu, pokud nejsou podmíněny specifickými požadavky trhu.

Navržené opatření by přineslo tyto konkrétní přínosy:

- zjednodušení vychystávacího procesu a snížení chybovosti,
- snížení nároků na skladovou plochu a přehlednější uskladnění,
- zrychlení manipulace díky menšímu počtu variant,

- snazší plánování zásob a přesnější evidence.

Z pohledu celkové efektivity lze návrh hodnotit jako prakticky realizovatelný a logicky odůvodněný. Nejedná se o zásah do základního produktového portfolia, ale o racionalizaci vnitřních procesů, která má potenciál zvýšit provozní efektivitu bez dopadu na zákaznické preference. Tímto opatřením lze přispět k celkovému zjednodušení logistiky a ke snížení nákladů spojených se správou zásob a interní manipulací.

ZÁVĚR

Tato diplomová práce se zabývala využitím datové analýzy a nástrojů Business Intelligence v oblasti interní logistiky, konkrétně v prostředí sekvenčního vychystávání ve společnosti ŠKODA AUTO a.s. Cílem této práce bylo na základě reálných provozních dat identifikovat díly s nízkým procentuálním zastoupením ve vychystávání a navrhnout opatření, která by vedla ke zjednodušení, zefektivnění a úspoře v rámci vnitropodnikových logistických procesů.

V teoretické části byly popsány klíčové pojmy a principy související s Big Data, vizualizačními nástroji a jejich využitím v logistice. Praktická část se zaměřila na analýzu vybraných sekvencí S19B, S39A a S39B, přičemž analýza vycházela z dat uložených v cloudovém úložišti Azure Blob Storage a zpracovaných pomocí Power BI. S ohledem na problematiku dané práce, která přesahovala běžný rámec studijního programu autora, bylo nezbytné, aby autor samostatně nastudoval celý proces prostřednictvím oficiálního portálu MICROSOFT LEARN.

Na základě této analýzy byly formulovány konkrétní návrhy. V případě sekvence S19B šlo o přebalení nízkofrekvenčních dílů do menších logistických jednotek, což umožňuje efektivněji využít skladovou plochu a zlepšit obrátkovost zásob. U sekvencí S39A a S39B bylo doporučeno omezit nebo sloučit díly s minimálním výskytem, čímž by došlo ke zjednodušení sortimentu, snížení nároků na skladování a zrychlení procesu vychystávání.

Při tvorbě návrhů byly zohledněny i zpětné vazby interních konzultantů ze ŠKODA AUTO, kteří upozornili na specifické požadavky trhu, zákazníků nebo legislativních omezení, kvůli nimž není možné některé varianty zcela zrušit. Z tohoto důvodu byly návrhy směřovány k opatřením, která jsou prakticky proveditelná a nezasahují do zákaznické nabídky.

Součástí výstupu je rovněž Power BI soubor, který umožňuje budoucí nahrávání dalších datových sad a vytváření aktuálních porovnaní na základě nově definovaných filtrů. Tento nástroj tak může sloužit jako podpora pro další rozhodování v oblasti skladového hospodářství.

Tato diplomová práce prokázala možnosti praktického využití problematiky Big Data v oblasti logistiky. Provedené analýzy ukázaly, že i relativně jednoduché úpravy, pokud jsou podloženy reálnými daty, mohou přinést znatelné zlepšení provozní efektivity, snížení nákladů a větší přehlednost interních procesů. Práce zároveň potvrdila, že nástroje jako Power BI představují vhodnou platformu pro reportování, vizualizaci a vyhodnocení provozních dat. Tento nástroj má potenciál stát se standardní součástí podpory rozhodovacích procesů v digitálně řízeném závodě.

POUŽITÁ LITERATURA

- CHEN, Min, Mao, SHIWEN, and Liu, YUNHAO, 2014. *Big Data: A Survey*. Mobile Networks and Applications [online]. [cit. 04.10.2024]. Dostupné z: <https://link.springer.com/article/10.1007/s11036-013-0489-0>
- COX, Michael and David ELLSWORTH, 1997. *Application-controlled demand paging for out-of-core visualization*. Proceedings of the 8th conference on Visualization '97. IEEE Computer Society Press [online] [cit. 04.10.2024]. Dostupné z: <https://ieeexplore.ieee.org/document/663888>
- DATA IDEOLOGY, 2024. *Power BI and Big Data: Unleashing Analytics Potential*. [online]. [cit. 23.01.2025]. Dostupné z: <https://www.dataideology.com/power-bi-and-big-data/>
- DATAQUEST, 2020. *Python vs. R: Which Should You Learn?* [online]. [cit. 04.10.2024]. Dostupné z: <https://www.dataquest.io/blog/python-vs-r/>.
- DE KOSTER, R., LE-DUC, T. A ZAERPOUR, N., 2012. *Determining the Number of Zones in a Pick-and-sort Order Picking System*. International Journal of Production Research. Dostupné z: <https://hal.science/hal-00711443/document>
- DHL, 2023. *Big Data in Logistics: What is the True Value of Data?* [online]. [cit. 30.11.2024]. Dostupné z: <https://dhl-freight-connections.com/en/trends/big-data-in-logistics-what-is-the-true-value-of-data/>
- DHL, 2024. *Big Data Analytics in Supply Chain Management*. [online]. [cit. 30.11.2024]. Dostupné z: <https://www.dhl.com/global-en/delivered/innovation/big-data-analytics-in-supply-chain-management.html>
- DHL, 2024. *ChatGPT and the Like: Artificial Intelligence in Logistics*. [online]. [cit. 30.11.2024]. Dostupné z: <https://dhl-freight-connections.com/en/trends/chatgpt-and-the-like-artificial-intelligence-in-logistics/>
- DOUBLE.CLOUD, 2023. *Big Data Visualization: Tools, Techniques, and Best Practices*. [online]. [cit. 23.01.2025]. Dostupné z: <https://double.cloud/blog/posts/2023/08/big-data-visualization/>.
- EFFECTIVESOFT, 2024. *AI in Logistics: How Does AI Impact the Logistics Sector?* [online]. [cit. 30.11.2024]. Dostupné z: <https://www.effectivesoft.com/blog/ai-in-logistics.html#how-does-ai-impact-the-logistics-sector->
- GANDOMI, Amir and Murtaza HAIDER, 2015. *Beyond the hype: Big data concepts, methods, and analytics*. International Journal of Information Management [online]. [cit. 04.10.2024]. Dostupné z: <https://www.sciencedirect.com/science/article/abs/pii/S0268401214001066>
- GRAND CANYON UNIVERSITY, 2019. *What Are the 4 V's of Big Data? GCU Blog* [online]. [cit. 04.10.2024]. Dostupné z: <https://www.gcu.edu/blog/engineering-technology/what-are-4-vs-big-data>

- GROLINGER, K., HIGASHINO, W.A., TIWARI, A. et al., 2013. *Data management in cloud environments: NoSQL and NewSQL data stores*. [online]. [cit. 04.10.2024]. Dostupné z: <https://doi.org/10.1186/2192-113X-2-22>
- IDC, 2018. *Data Age 2025: The Digitization of the World From Edge to Core*. [online]. [cit. 04.10.2024]. Dostupné z: <https://www.seagate.com/files/www-content/our-story/trends/files/idc-seagate-dataage-whitepaper.pdf>
- JEHLIČKA, Aleš, 2022. *Odvolávání materiálu montážní linkou ve ŠKODA AUTO a.s.*. Online. Bakalářská práce. Pardubice: Univerzita Pardubice, Dopravní fakulta Jana Pernera. 2022. Dostupné z: <https://theses.cz/id/nhjc15/>.
- KAMBATLA, K., KOLLIAS, G., KUMAR, V., and GRAMA, A., 2014. *Trends in big data analytics*. Journal of Parallel and Distributed Computing [online]. [cit. 04.10.2024]. Dostupné z: <https://www.sciencedirect.com/science/article/abs/pii/S0743731514000057>
- KAMBLE, Sachin, GUNASEKARAN, Angappa and Shradga A. GAWANKAR, 2020. *Achieving sustainable performance in a data-driven agriculture supply chain: A review for research and applications*. Journal of Cleaner Production. [online]. [cit. 30.11.2024]. Dostupné z: <https://www.sciencedirect.com/science/article/abs/pii/S0925527319302038>
- KLUMPP, Matthias a Caroline RUINER, 2021. *Digital supply chains and the human factor*. Cham: Springer Nature. ISBN 978-3-030-58429-0.
- LANEY, Doug, 2001. *3D Data Management: Controlling Data Volume, Velocity, and Variety*. Meta Group [online]. [cit. 04.10.2024]. Dostupné z: <https://www.coursehero.com/file/32221989/3D-Data-Management-Controlling-Data-Volume-Velocity-and-Varietypdf/>
- LECUN, Yann, Yoshua BENGIO, and Geoffrey HINTON, 2015. *Deep Learning*. ResearchGate [online]. [cit. 30.11.2024]. Dostupné z: https://www.researchgate.net/publication/277411157_Deep_Learning
- LUCA, 2023. *Pick-by-Vision*. LUCA Logistic Solutions [online]. [cit. 14.03.2025]. Dostupné z: <https://www.luca.eu/en/picking/pick-by-vision/>
- LUU, K., ET AL., 2023. *Applying artificial intelligence and digital health technologies, Viet Nam*. Bulletin of the World Health Organization, 101 (7), 487-492. Dostupné z: <https://iris.who.int/handle/10665/370744>
- MARR, Bernard a SCHMARZO, Bill, 2016. *Big Data in Practice: How 45 Successful Companies Used Big Data Analytics to Deliver Extraordinary Results*. Hoboken: Wiley. ISBN 978-1119231387.
- MAYER-SCHÖNBERGER, Viktor a CUKIER, Kenneth, 2013. *Big Data: A Revolution That Will Transform How We Live, Work, and Think*. Boston: Houghton Mifflin Harcourt, 2013. ISBN 978-0544002692
- MICROSOFT LEARN, 2025a. *Quickstart: Create a blob in the Azure portal* [online]. [cit. 17. 4. 2025]. Dostupné z: <https://learn.microsoft.com/en-us/azure/storage/blobs/storage-quickstart-blobs-portal>

- MICROSOFT LEARN, 2025b. *Connect to Azure Blob Storage in Power BI Desktop* [online]. [cit. 17. 4. 2025]. Dostupné z: <https://learn.microsoft.com/en-us/power-bi/connect-data/desktop-connect-azure-blob-storage>
- MICROSOFT LEARN, 2025c. *Combine and transform binary files in Power BI Desktop* [online]. [cit. 17. 4. 2025]. Dostupné z: <https://learn.microsoft.com/en-us/power-bi/connect-data/desktop-combine-binaries>
- MICROSOFT, 2023. Introduction to Azure Blob Storage. Microsoft Learn [online]. Copyright © 2023 [cit. 28.02.2025]. Dostupné z: <https://learn.microsoft.com/cs-cz/azure/storage/blobs/storage-blobs-introduction>
- MICROSOFT, 2024. *What is Power BI Desktop?* [online]. [cit. 23.01.2025]. Dostupné z: <https://learn.microsoft.com/en-us/power-bi/fundamentals/desktop-what-is-desktop>
- NUMERRO, 2023. *Top 10 Power BI Dashboard Examples*. [online]. [cit. 23.01.2025]. Dostupné z: <https://www.numerro.io/guides/top-10-power-bi-dashboard-examples-free-template>
- PASSIONNED, 2023. *5 V's of Big Data*. [online]. [cit. 23.01.2025]. Dostupné z: <https://www.passionned.com/wp/wp-content/uploads/5-vs-big-data.png>.
- PAYNE, Matt, 2021 *3 Ways Machine Learning is Transforming the Logistics Industry*. Unite.ai [online]. [cit. 30.11.2024]. Dostupné z: <https://www.unite.ai/cs/3-ways-machine-learning-is-transforming-the-logistics-industry/>
- PHOENIXNAP, 2020. *Hadoop vs Spark: A Comparison of Big Data Technologies*. [online]. [cit. 04.10.2024]. Dostupné z: <https://phoenixnap.com/kb/hadoop-vs-spark>.
- PICK TO LIGHT SYSTEMS, 2025. Pick by Light. Pick to Light Systems [online]. [cit. 14.03.2025]. Dostupné z: <https://www.picktolightsystems.com/en/picking-products/pick-by-light>
- POWER BI, 2025. *Microsoft Power BI* [online]. Redmond, WA: Microsoft, [cit. 2025-16-03]. Dostupné z: <https://powerbi.microsoft.com/>
- QUADER, S. A CASTILLO-VILLAR, K.K., 2018. *Design of an Enhanced Multi-Aisle Order-Picking System Considering Storage Assignments and Routing Heuristics*. *Robotics and Computer-Integrated Manufacturing*, 50, 13-29. Dostupné z: <https://www.scirp.org/reference/referencespapers?referenceid=2402501>
- Řehák, Miroslav, 2022. *Komplexita skel* [interní materiál]. Kvasiny: ŠKODA AUTO a.s.
- ŠKODA AUTO, 2025. Historie 1895–1906 [online]. 2025 [cit. 25.02.2025]. Dostupné z: <https://www.skoda-auto.cz/o-spolecnosti/historie-1895-1906>
- ŠRÁMKOVÁ, Františka, 2022. *Zlepšení procesu vychystávání ve vybrané společnosti*. Online. Diplomová práce. Přerov: Vysoká škola logistiky o.p.s. 2022. Dostupné z: <https://theses.cz/id/5aimv5/>.

SSI SCHAEFER, 2025. *Vychystávání*. SSI SCHAEFER [online]. [cit. 28.02.2025]. Dostupné z: [https://www.ssi-schaefer.com/cs-](https://www.ssi-schaefer.com/cs-cz/%C5%99e%C5%A1en%C3%AD/procesy/vychyst%C3%A1v%C3%A1n%C3%AD)

[cz/%C5%99e%C5%A1en%C3%AD/procesy/vychyst%C3%A1v%C3%A1n%C3%AD](https://www.ssi-schaefer.com/cs-cz/%C5%99e%C5%A1en%C3%AD/procesy/vychyst%C3%A1v%C3%A1n%C3%AD)

THREAD IN MOTION, 2021. *Pick by Voice in Logistics*. Thread in Motion [online]. [cit. 14.03.2025]. Dostupné z: <https://www.threadinmotion.com/en/blog/pick-by-voice-in-logistics>

TOMPKINS, James A., WHITE, John A., BOZER, Yavuz A. a TANCHOCO, J. M. A., 2010. *Facilities Planning*. 4. vyd. John Wiley & Sons. ISBN 0470444045.

WHITE, Tom, 2012. *Hadoop: The Definitive Guide*. 4th ed. Sebastopol: O'Reilly Media. ISBN 9781449311520.

ZIKOPOULOS, Paul a EATON, Chris, 2011. *Understanding Big Data: Analytics for Enterprise Class Hadoop and Streaming Data*. New York: McGraw-Hill. ISBN 978-0071790536.

SEZNAM TABULEK

Tabulka 1	Čísla dílů levého bočního skla v sekvenci S19B	45
Tabulka 2	Procentuální vychystávání dílů v sekvenci S19B	47
Tabulka 3	Čísla dílů volantů v sekvenci S39A	52
Tabulka 4	Procentuální vychystávání dílů v sekvenci S39A	53
Tabulka 5	Čísla dílů volantů v sekvenci S39B pro SEAT Alteca.....	56
Tabulka 6	Procentuální vychystávání dílů pro SEAT Alteca	57

SEZNAM OBRÁZKŮ

Obrázek 1	Big Data a jejich 5 V.....	13
Obrázek 2	Proces zpracování a vizualizace dat.....	16
Obrázek 3	Logistický dashboard v Power BI.....	19
Obrázek 4	Pick by Light.....	25
Obrázek 5	Brýle pro vychystávání pomocí Pick by Vision.....	26
Obrázek 6	Pick by Voice.....	27
Obrázek 7	Vizualizace dat z interního systému ŠKODA AUTO.....	32
Obrázek 8	Vytvoření účtu úložiště.....	35
Obrázek 9	Vytvoření kontejneru.....	36
Obrázek 10	Nahrávání dat do kontejneru bigdata.....	37
Obrázek 11	Načtení dat z Azure Blob Storage.....	38
Obrázek 12	Propojení přes URL.....	38
Obrázek 13	Načtená data v binárním formátu.....	39
Obrázek 14	Převod binárních dat na text.....	40
Obrázek 15	Výsledná tabulka dat.....	41
Obrázek 16	Návrh tvorby modelu.....	44
Obrázek 17	Filtr pro požadovanou sekvenci.....	46
Obrázek 18	Graf procentuálního zastoupení vychystávání dílů v sekvenci S19B.....	47
Obrázek 19	Počet okrajově vychystávaných dílů v sekvenci S19B.....	48
Obrázek 20	Standardní balení volantů.....	51
Obrázek 21	Náhradní balení volantů.....	52

SEZNAM ZKRATEK

AI	Artificial Intelligence Umělá inteligence
BI	Business Intelligence
BMA	Bedarfsorientierter Materialabruf Požadavkově řízené zásobování materiálem
FIS	Fertigungsinformationssystem Výrobní informační systém
GLT	Großladungsträger Velká přepravní jednotka
HDFS	Hadoop Distributed File System
ICT	Information and Communication Technology Informační a komunikační technologie
IoT	Internet of Things Internet věcí
KLT	Kleinladungsträger Malá přepravní jednotka
KPI	Key Performance Indicator Klíčové ukazatele výkonnosti
RFID	Radio Frequency Identification Identifikace pomocí rádiové frekvence
SAS	Shared Access Signature Sdílený přístupový podpis
URL	Uniform Resource Locator Jednotný identifikátor zdroje (webová adresa)
VIN	Vehicle Identification Number Identifikační číslo vozidla
WLAN	Wireless Local Area Network Bezdrátová lokální síť