

Univerzita Pardubice
Dopravní fakulta Jana Pernera

Prediktivní plán údržby vozidel

Jaromír Šulc

Disertační práce
2024

Doktorand

Ing. Jaromír Šulc

Studijní program

Technologie a management v dopravě

Školitel

prof. Ing. Radovan Soušek, Ph.D.

Prohlašuji:

Tuto práci 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., autorský zákon, 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. 9/2012, bude práce zveřejněna v Univerzitní knihovně a prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 25.11.2024

Anotace

Tato disertační práce se zaměřuje na problematiku údržby vozového parku dopravců provozujících městskou hromadnou dopravu. Hlavním cílem je vytvoření modelu časového plánu údržby vozidel, vyčíslení nákladů na realizaci plánované i neplánované údržby. Práce analyzuje historický vývoj automobilového průmyslu a jeho vliv na současné požadavky na údržbu vozidel.

V rámci práce jsou navrženy postupy a algoritmy pro urychlení a zpřesnění procesů tvorby plánů údržby a souvisejících rozpočtů. Tyto postupy umožňují kontrolu průběžných výsledků a uživatelské vstupy do procesů predikce nákladů, využití vozového parku a predikce výkonů jednotlivých vozidel. Práce také poskytuje praktické návody na implementaci navržených postupů v provozním prostředí dopravních podniků.

Výsledky práce jsou validovány na provozních datech vybraného dopravního podniku městské hromadné dopravy. Hlavní výhody navrženého postupu zahrnují zrychlení a zpřesnění tvorby plánů údržby, vyčíslení nákladů na údržbu a vytvoření vstupů pro funkční plán skladových zásob.

Klíčová slova

Údržba vozidel, městská hromadná doprava, plán údržby, neplánovaná údržba, pravidelná údržba, náklady na údržbu, P-graph, process-network synthesis, Poissonova regrese, ARRIMA

Title

Predictive vehicle maintenance plan

Annotation

This dissertation focuses on the issue of maintenance of the fleet of carriers operating public transport. The main objective is to create a model of the vehicle maintenance schedule, quantifying the costs for the implementation of planned and unplanned maintenance. The thesis analyses the historical development of the automotive industry and its influence on the current vehicle maintenance requirements.

The thesis proposes procedures and algorithms to speed up and refine the process of developing maintenance schedules and associated budgets. These procedures allow for the control of intermediate results and user input into the processes of cost prediction, fleet utilization, and

individual vehicle performance prediction. The paper also provides practical guidance on the implementation of the proposed procedures in the operational environment of transport companies.

The results of the work are validated on operational data of a selected public transport enterprise. The main benefits of the proposed approach include speeding up and refining the creation of maintenance plans, quantifying maintenance costs and generating inputs for a functional inventory plan.

Keywords

Vehicle maintenance, public transport, maintenance plan, P-graph, process-network synthesis, Poisson regression, ARRIMA, unscheduled maintenance, scheduled maintenance, maintenance costs

OBSAH

OBSAH.....	3
SEZNAM OBRÁZKŮ.....	5
SEZNAM TABULEK.....	6
SEZNAM ROVNIC	7
SEZNAM ALGORITMŮ	8
SEZNAM SYMBOLŮ A ZKRATEK ZKRATEK	9
ÚVOD	11
1 SOUČASNÝ STAV PROBLEMATIKY ÚDRŽBY VOZIDEL.....	13
1.1 ÚDRŽBA.....	13
1.1.2 Vývoj údržby	14
1.1.3 Typy údržby.....	15
1.2 PLÁN ÚDRŽBY	17
1.3 PREDIKCE CENY	18
1.4 PREDIKTIVNÍ ÚDRŽBA	20
1.5 TYPY PREDIKTIVNÍ ÚDRŽBY	21
1.5.1 Fyzikální metody.....	21
1.5.2 Znalostní modely	21
1.5.3 Metody založené na zpracování dat.....	22
1.5.4 Statistické a stochastické přístupy.....	22
1.5.5 Strojová učení.....	22
1.5.6 Tradiční algoritmy	23
1.6 METODY PLÁNOVÁNÍ ÚDRŽBY VOZIDEL POUŽÍVANÉ V ČESKÉ REPUBLICE	23
1.7 SHRNUÍ AKTUÁLNÍHO STAVU PLÁNOVÁNÍ ÚDRŽBY	27
2 CÍL DISERTAČNÍ PRÁCE	30
3 PŘEHLED METOD POUŽITÝCH K DOSAŽENÍ CÍLE PRÁCE.....	31
3.1 ANALÝZA STÁVAJÍCÍHO PROCESU	31
3.1.1 Predikce časových řad	31
3.1.2 Model procesu a simulace	33
3.1.3 Modely pro predikci skladových zásob.....	33

3.1.4	<i>Poissonova regrese</i>	34
3.2	PŘÍPADOVÁ STUDIE.....	34
3.3	METODY PRAKTICKÉ.....	35
4	POSTUP PREDIKTIVNÍHO PLÁNOVÁNÍ ÚDRŽBY VOZIDEL	36
4.1	PŘEDPOKLADY NÁVRHU POSTUPU A ALGORITMŮ	36
4.2	OPOMÍJENÉ PODMÍNKY	37
4.2.1	<i>Kapacity zdrojů pro provádění plánované i neplánované údržby</i>	37
4.2.2	<i>Obsluhované spoje a linky</i>	38
4.2.3	<i>Heterogenní vozový park</i>	39
4.3	DATOVÉ ZDROJE.....	39
4.3.1	<i>Existující datové zdroje</i>	40
4.3.2	<i>Nově definované datové zdroje</i>	41
4.3.3	<i>Editovatelné průběžné výsledky</i>	41
4.3.4	<i>Výsledky prediktivního plánu údržby</i>	42
4.4	POSTUP TVORBY PREDIKTIVNÍHO PLÁNU ÚDRŽBY.....	42
4.4.1	<i>Preprocessing 1 - km koeficient vozu</i>	43
4.4.2	<i>Preprocessing 2 – Predikce cen plánované údržby dle typu</i>	47
4.4.3	<i>Preprocessing 3 – Predikce cen ostatní údržby</i>	48
4.5	VÝPOČET PREDIKTIVNÍHO PLÁNU ÚDRŽBY.....	51
4.5.1	<i>Grafová interpretace</i>	51
4.5.2	<i>Generování grafu</i>	54
4.5.3	<i>Opomíjené podmínky</i>	56
4.6	SHRNUTÍ NAVRHOVANÉHO POSTUPU	57
5	PŘÍPADOVÁ STUDIE	59
5.1	ZPRACOVÁNÍ DATABÁZOVÝCH DAT.....	59
5.2	ČIŠTĚNÍ DAT	63
	ZÁVĚR	65
	POUŽITÁ LITERATURA	67

SEZNAM OBRÁZKŮ

Obrázek 1 Kompromis vztahu nákladů na opravdu a na prevenci (Arena, Collotta, Luca, Ruggieri, & Termine, 2021).....	19
Obrázek 2 Existující a neexistující datové zdroje (autor)	29
Obrázek 3 Mapa užití datových zdrojů (autor).....	40
Obrázek 4 Postup tvorby prediktivního plánu údržby a vyčíslení nákladů (autor)	43
Obrázek 5 Ukázka vypočtených km koeficientů pro trolejbusy Solaris Trollino (autor).....	45
Obrázek 6 Srovnání skutečných a odhadovaných kilometrických proběhů jednotlivých typů vozidel (autor)	46
Obrázek 7 Plán kilometrických proběhů v detailu na jednotlivá vozidla (autor)	47
Obrázek 8 Odhadnuté ceny jednotlivých typů údržby (autor).....	48
Obrázek 9 Ukázka procentuálního podílu nákladů neplánované údržby vůči nákladům plánované údržby (autor)	50
Obrázek 10 Vypočítané roční náklady na údržbu po poruše, resp. nehodě (autor).....	50
Obrázek 11 Ukázka odhadu doby trvání preventivních údržbových zásahů (autor)	51
Obrázek 12 Graf reprezentující jednotky údržby (Adonyi, Heckl, & Olti, 2013).....	52
Obrázek 13 PNS síť zahrnující tři provozní jednotky a čest materiálů (Adonyi, Heckl, & Olti, 2013)	52
Obrázek 14 P-graph realizace údržby vozidel (autor)	54
Obrázek 15 Proces nepřímého vyčítání a zpracování dat (autor)	60
Obrázek 16 Prezentace plánu údržby v Power BI (autor)	61
Obrázek 17 Proces provozního načítání a zpracování dat (autor)	63

SEZNAM TABULEK

Tabulka 1 Plán km - příklad (autor).....	25
Tabulka 2 Předpis plánované údržby – příklad (autor).....	26
Tabulka 3 Časová náročnost nepřímého načítání a zpracování dat (autor).....	62

SEZNAM ROVNIC

Rovnice 1 Kumulativní náklady na údržbu (Grall, Bérenguer, & Dieulle, 2002).....	18
Rovnice 2 Poissonova distribuce	34

SEZNAM ALGORITMŮ

Algoritmus 1 Výpočet km koeficientu (autor).....	44
Algoritmus 2 Výpočet plánu kilometrů (autor)	44
Algoritmus 3 Výpočet ceny plánované údržby (autor).....	47
Algoritmus 4 Výpočet ceny neplánované údržby (autor).....	49
Algoritmus 5 Postup tvorby P-grafu pro údržbu vozidel (autor).....	55
Algoritmus 6 Algoritmus nastavení prohlídek (autor).....	56

SEZNAM SYMBOLŮ A ZKRATEK ZKRATEK

ABB	Accelerated branch and bound
AI	Artificial intelligence / Umělá inteligence
B&B	Branch nad bound
CBM	Condition-based maintenance / Údržba založení na stavu
Cc	Corrective replacement cost / Náklady spojené s opravou/výměnou
Cd	Downtime cost / Náklady spojené s jednotkovými prostoji
Ci	Inspection cost / Náklady na kontrolu
Cp	Preventive replacement cost / Náklady spojené s preventivní opravou/výměnou
E	Edge / Hrana
E	Set of edges / Seznam hran
DT	Decision tree / Rozhodovací strom
G	Graph / Graf
GPR	Regrese Gaussova procesu
IS	Information system / Informační systém
IT	Information technology / Informační technologie
JŘ	Jízdní řád
k-NN	K-nearest neighbors algorithm / Metoda nejbližších sousedů
LR	Lineární regrese
ML	Machine learning / Strojové učení
OS	Odborná skupina
PNS	Process-network synthesis
RCM	Reliability centered maintenance / Údržba zaměřená na spolehlivost
SPZ	Státní poznávací značka
SVM	Support vector machines / Metoda podpůrných vektorů
T	Trip / Spoj
TP	technická prohlídka
TPM	Total productive maintenance / Údržba založená na produktivitě
V	Vertex / Vrchol
V	Set of verties / Seznam vrcholů

VDM

Value driven maintenance / Údržba založená na ceně

ÚVOD

Jedním z hlavních pokroků vědy a techniky byl rozmach strojírenské výroby, která se v 19. století soustředila na automobilový průmysl. S možnostmi doby a prvními vynálezy došlo ke konstrukci prvních jednoduchých vozů. První automobil byl konstruován se vznětovým motorem, který byl ale velmi nebezpečný. Avšak s narůstajícími dopravními požadavky a zvyšujícími se nároky na pohodlnost dopravy došlo k několika pokrokům. Vývoj v automobilovém průmyslu dosahoval stále vyšších výkonů a přepravních kapacit. S nárůstem požadavků však narůstala i potřeba udržovat chod jednotlivých strojů a dbát nejen na plynulost dopravy, ale i bezpečnost. K plnění těchto požadavků přistoupil opravárenský průmysl.

V dnešní době však existují mnohem vyšší požadavky, které plynou z neustále se měnících předpisů a zákonů. Stále platí, že primárním cílem je brát ohled na bezpečnost a spolehlivost vozidel s cílem snížit ekologický dopad na životní prostředí. Vzhledem k těmto faktorům dochází k neustálému vývoji nových technologií, které ovlivňují složitější konstrukci a elektronizaci vozidel. Ovšem stále platí, že čím složitější systém, tím častější údržba. Vzhledem k aktuálnímu trendu v produkci vozidel prochází vývojem i opravárenský průmysl a údržba.

Neustále měnící se konstrukční postupy vozidel ovlivňují také soustavně vývoj nových opravárenských a diagnostických systémů. Bezpečnost a spolehlivost vozidel je proto odkázána na pravidelnou a modernizovanou údržbu. Údržba je důležitým a nezbytným faktorem, potřebným pro včasnou diagnostiku aktuálního stavu vozidla, včetně určení potřebných výměn a oprav jednotlivých součástí konstrukce.

Tato práce je zaměřena cíleně na problematiku údržby vozového parku dopravců provozující městskou hromadnou dopravu. Tyto dopravní podniky jsou charakteristické tím, že dopravce zpravidla provozuje větší množství vozidel každého typu, jednotlivé typy vozidel jsou provozovány na jasně určených linkách z důvodu jejich kapacit a výkonu a konkrétní vozy mají velmi různorodou historii výkonů, poruch a nehod, přičemž část vozidlové flotily je zpravidla ještě v záručním servisu a část již naopak za minimálně morální životností.

Podklady pro tvorbu plánů údržby se v čase mění a jejich aktualizace bývá náročným procesem, jelikož samotný fyzický plán údržby zasahuje i do ekonomického plánování a musí spadat do ekonomického rámce, který má daný dopravní podnik k dispozici. Např. v době

covidových uzávěr docházelo i k významné redukci a opětovnému navyšování dopravních výkonů dopravců. Dále byly zcela nepredikovatelné příjmy dopravců a tlak ze strany vlastníků dopravců na okamžitou minimalizaci nákladů i se zaměřením na údržbu vozidel. Do procesu plánování údržby vstupuje postupné vyřazování zastaralých vozidel a nákup nových, ale i nepředvídatelné události jako nehody, chybějící náhradní díly a další zdroje pro realizaci samotné údržby (chybějící lidské zdroje, již obsazené odstavné koleje apod.). Manažerské rozhodování v rámci plánování údržby vozidel tedy představuje složitou úlohu, která vyžaduje v praxi i tvorbu alternativních plánů údržby dle zadaných parametrů.

Proto je cílem této disertační práce zaměřením na údržbu vozidel, konkrétně prediktivní plán údržby, jehož cílem je vytvořit model optimálního časového plánu údržby vozidel, zajišťujících spolehlivost, bezpečnost, nízký ekonomický a ekologický dopad provozu jednotlivých vozidel a dopravního podniku jako celku.

Model optimálního časového plánu bude již v rámci této disertační práce validován na provozních datech vybraného dopravního podniku městské hromadné dopravy provozujícího všechny trakce povrchové dopravy (autobusy, tramvaje, trolejbusy).

1 SOUČASNÝ STAV PROBLEMATIKY ÚDRŽBY VOZIDEL

Spolehlivost a kontrola kvality spojená s výběrem optimálních způsobů údržby by v současné době nemohla existovat bez dobře plánovaného a diagnostického postupu. Samotná údržba se z důvodu využívání technické diagnostiky a nových programů dostala na novou úroveň. Aplikace inovativních konstrukcí, materiálů, technologických řešení je vždy doprovázena výzkumem jejich spolehlivosti i bezpečnosti provozu. Souvislost mezi spolehlivostí, technickým stavem vozidel a rizikem nehod, potvrzují studie různých autorů (Moroz, 2005). Pro zajištění určité úrovně technické dostupnosti a bezpečnosti technického stavu vozidel jsou vytvořeny provozované systémy provozu a údržby (Verevkin, 2017).

Efektivnost a účinnost údržby určuje úroveň spolehlivosti pozorovaného zařízení (Sari & Ridho, 2016). Jednotlivé činnosti a aktivity údržby mají za cíl zajistit, aby dané objekty fungovaly podle toho, jaké jsou aktuální požadavky uživatele. Údržba souvisí nejen s více postupy, úkoly, pokyny, ale i kvalifikací personálu a zdroji potřebnými pro údržbu sledovaného zařízení či pro zlepšení jeho aktuální činnosti. Správná údržba může zvýšit dlouhodobou produktivitu, zachovat funkční úroveň produktu a snížit neplánované prostoje (Ni J, 2015).

1.1 Údržba

Pojem údržba vozidel má mnoho definic, ale obecně představuje složitý a komplexní proces. Bez ohledu na druh zařízení, je provozování údržby a jednotlivých kroků v rámci platných předpisů náročné. Hlavním úkolem opravárenského průmyslu a jednotlivých odborníků v dané oblasti je nalezení nejefektivnějšího způsobu udržení daného zařízení při bezpečném chodu (Skřivánek, 1976).

Hlavním úkolem programu údržby je zajistit bezproblémový chod vozidel, zabránit zhoršení jejich spolehlivosti a udržet životnost a trvanlivost vozidel v předepsaných mezích (Skřivánek, 1976). Obecně lze říci, že údržba vozidel je proces, kterým dochází k řízení administrativních a technických činností během životního cyklu daného zařízení. Podle (Lehder, 2000) je cílem údržby nejen udržet, ale také obnovit stav zařízení, ve kterém lze vykonávat požadovanou funkci s apelem na kvalitu, bezpečnost, optimální náklady a environmentální požadavky.

(Kobbacy, 2008) popisují klíčový cíl údržby jako „*optimalizaci celkového životního cyklu zařízení*“. To znamená, že maximalizace dostupnosti a spolehlivosti zařízení musí být

dosaženo nákladově efektivním způsobem a v souladu s environmentálními a bezpečnostními předpisy.

(Furch, 2010) charakterizoval držbu jako: „*souhrn všech technických, administrativních a manažerských činností během životního cyklu věci, jejichž cílem je udržet věc ve stavu, případně vrátit ji do stavu, ve kterém může plnit požadovanou funkci.*“ Jednou z definic údržby je charakterizovat ji jako komplex činností zabezpečující způsobilost a ekonomicky výhodný provoz vybraných zařízení. Také je definována jako souhrn opatření zajišťující posouzení skutečného stavu objektu a zajištění zachování, resp. obnovení požadovaného stavu. Podle (Lehder, 2000) mezi jednotlivé činnosti údržby zařazujeme:

- Základní údržba (promazání, čištění).
- Kontrola a revizní prohlídky.
- Detekce poruch.
- Oprava.

Realizace údržby probíhá podle předem stanovených pravidel, která jsou spojena s podrobným časovým plánováním.

1.1.2 Vývoj údržby

Vývoj údržby v průběhu času zaznamenal různá realizační a koncepční stadia, determinovaná tehdejší technologickou úrovní zařízení. Během dlouhého období (14.-15.století) se až do začátku 20. století považovala údržba zařízení za řemeslný typ práce. Její podstata vycházela z činností zaměřených na udržování technického stavu a výměna zařízení obnovující jejich technický stav a většinou se považovala za nezbytné náklady (Virca I. and Badea, 2019).

Ve druhé polovině 20.století v návaznosti na rozvoj militaristického a dopravního průmyslu nabývala údržba na novém významu. Teorie a praxe údržby se vyvíjely a byly přizpůsobeny tak, aby splňovaly vyšší požadavky na efektivitu a produktivitu a zvyšující se složitost systémů a zařízení (Pintelon L., 2008).

V roce 1950 byla údržba považována za opravný typ činnosti, který předpokládal, že oprava technického zařízení je provedena, až když dojde k poruše. Teorie údržby byla v této době založena na technickém inženýrství a souvisela s přítomností poruchy, opotřebování materiálu. Velký důraz byl kladen hlavně na spolehlivost zařízení.

V průběhu 50.-70.let 20 století měla údržba preventivně plánovaný charakter, který zahrnoval nepřetržitou údržbu a opravy podle potřeby. Teorie údržby byla založena na složitějších konceptech ekonomického inženýrství, efektivnosti, životním cyklu materiálu a odvíjela se od přísných plánů údržby.

Během 70. a 80. let 20. století došlo k masivnímu průniku průmyslové elektroniky do konstrukce technických zařízení, což souviselo s vývojem výrobních systémů, zlepšováním kvality a designu. Implicitní šíření těchto znalostí vedlo k vyšší úrovni celé průmyslové teorie a praxe spojené s údržbou.

Koncem 20. století však průmyslová perspektiva získala širší pozornost v oblasti řízení a plánování údržby (Pintelon L., 2008). V první dekádě nového tisíciletí se do centra pozornosti dostaly tzv. náměstí. „koncepty údržby na míru“ (Pintelon L., 2008). V důsledku toho bylo manažerům doporučeno, aby se nezaměřili pouze na náklady na údržbu, ale také na hodnotu služeb údržby. Podle (Pinjala, 2006) to znamenalo, že údržba se stala pro firmy otázkou strategického významu. Kromě toho autoři tvrdí, že je třeba dále řešit propojení mezi strategickými a provozními aspekty údržby. Rovněž by měla být věnována dodatečná pozornost i tomu, jak může údržba zlepšit produktivitu a efektivitu. Tvrdí zejména, že analýzu nákladů na údržbu je třeba doplnit širší analýzou zahrnující výkon, produktivitu, hodnotu a výnosy.

1.1.3 Typy údržby

Údržba a její realizace představuje aktuální téma. Přiměřená údržba je jedním z faktorů odpovídajících za pracovní výkon a nákladovou efektivnost společností. Přispívá ke zvyšování spolehlivosti zařízení a zajišťuje chod běžných výrobních procesů (Ghajargar, Zenezini, & Montanaro, 2016). Právě proto ji (Duffuaa, Ben-Daya, Al-Sultan, & Andijani, 2001) označil za klíčovou podmínku podniků a společností ovlivňující udržení jejich konkurenční výhody. Údržba se může provádět prostřednictvím různých akcí a existují různé klasifikace typů údržby (Duffuaa, Ben-Daya, Al-Sultan, & Andijani, 2001). Údržba může být rozdělena na dvě hlavní činnosti, a to nápravnou a preventivní. (Shin & Jun, 2015) klasifikují údržbu do tří typů: opravná údržba, preventivní údržba a údržba založená na stavu (condition-based maintenance, CBM).

Podobnou klasifikaci uvedl i (Stuchlý, 1988), když definoval tři strategie údržby a to:

- Proaktivní, resp. preventivní: jejím hlavním účelem je zamezení vzniku poruch zařízení. Rovněž zahrnuje preventivní a prediktivní způsob údržby. Dělí se do tří mezi kroků a to:

- plánovaná obnova,
 - plánované vyřazení
 - a určení podmínek sledovaného stavu.
- Diagnostická: jejím hlavním úkolem je monitorování aktuálních vlastností a parametrů a příprav vhodných opatření.
 - Po poruše: dochází k ní až po diagnostikování poruchového stavu s cílem na opravu poruchy a přivedení daného zařízení do funkčního stavu.

Obecně lze však definovat až čtyři typy údržby: údržba z důvodu opravy, preventivní údržba, prediktivní údržba a proaktivní údržba. V minulosti firmy často využívaly preventivní údržbu ke snížení nákladů za kontrolu a celkovou údržbu (De Faria, Costa, & Olivas, 2015); (Ghajargar, Zenezini, & Montanaro, 2016). (Bousdekis, 2018) uvedl, že provádění preventivní údržby by mohlo vést k nahrazení jednotlivých součástí příliš brzy, což může vést ke zvýšení obchodních nákladů. Proto s rozvojem a inovací průmyslu a technologií se údržba postupně přizpůsobuje na prediktivní údržbu.

1.2 Plán údržby

Plánování údržby zahrnuje celou škálu metod zabezpečujících údržbu, opravu resp. výměnu sledovaného zařízení. Hlavním cílem plánování údržby je minimalizace celkových nákladů na kontrolu, opravy a prostoje vznikající z nefunkčnosti zařízení (Mirghani, 2001).

Vysoká úroveň automatizace iniciovala pokrok v oblasti údržby strojů. (Ben-Daya & Duffuaa, 1995) popsal, že činnosti spojené s údržbou zařízení byly stále důležitější v kontextu kvality a výrobních nákladů. Souvislost s kvalitou práce a výrobních nákladů přímo ovlivňovalo zvýšení výdajů na údržbu a pracovníků údržby. V některých odvětvích proto stále existuje oddělení údržby jako největší oddělení, která tvoří přibližně 30 % celkové pracovní síly (Bjorklund, 2010).

V tomto stavu je proto správné vypracování postupů a strategií pro tvorbu údržbových systémů klíčovým faktorem optimalizace celkové strategie údržby. Problémem je, že většinou dané strategie nenabízejí akční plán pro provozní úroveň. Mnoho strategií plánování činností údržby zdůrazňuje strategii, která je obvykle spojena se zodpovědnostmi managementu na nejvyšší a střední úrovni. To znamená, že zaměstnanci na provozní úrovni často plní úkoly údržby, které jsou příliš obecné a obtížně přenosné na plán údržby.

Hlavní nevýhodou těchto strategií údržby pro provozní úroveň je však to, že vyžadují vstupní informace, které je obtížné získat. Tento názor podporují (Sharma, 2005) a poukazují na to, že mnohé z vstupních těchto faktorů není snadné vyhodnotit z důvodu nejistot spojených s odhadem charakteristik selhání/opravy jednotlivých komponent zařízení. Tyto úvahy naznačují, že:

- Většina strategií údržby je navržena pro vrcholový management. V tomto bodě je problémem implementace do výrobního systému.
- Tyto strategie údržby vyžadují na provozní úrovni vstupní informace k vypracování plánu údržby.

V posledních letech proto bylo možné sledovat změny ve formě vyvinutí několika modelů, metod, konceptů a strategií s cílem vhodně rozplánovat a hodnotit činnost údržby a kvantifikovat její efektivitu (Lundgren, Skoogh, & Bokrantz, 2018). Mezi některé modely plánování údržby lze zařadit Value Driven Maintenance (VDM) (Haarman H, 2004)), Total Productive Maintenance (TPM) (Nakajima, 1988), Reliability Centered Maintenance (RCM) (Rausand, 1998) a Total quality maintenance (Al-Najjar, 1996).

1.3 Predikce ceny

Náklady na údržbu představují klíčový faktor při výběru způsobu realizované údržby. Při odhadování nákladů na údržbu je třeba zohlednit celkové náklady a efektivitu daného druhu údržby za účelem snížení nákladů a zvýšení produktivity. Model pro výpočet nákladů se mění v závislosti na tom, jak se mezi sebou liší jednotlivé strategie údržby.

V případě reaktivní údržby dochází k činnosti až po detekci poruchy. To znamená, že náklady na údržbu jsou spojeny s opravou neboli nápravnou výměnou (corrective replacement cost, C_c). V případě preventivní údržby jsou jednotlivé činnosti naplánovány a náklady jsou spojeny s preventivní výměnou součástí, prostoji a celkovou kontrolou naplánované činnosti postupné údržby. Celkové náklady často zahrnují náklady související s preventivní výměnou a opravou (preventive replacement, C_p ; C_c), náklady na kontrolu (inspection cost, C_i), náklady související s jednotkovými prostoji (downtime cost, C_d) a náklady spojené s opravnou výměnou (C_c).

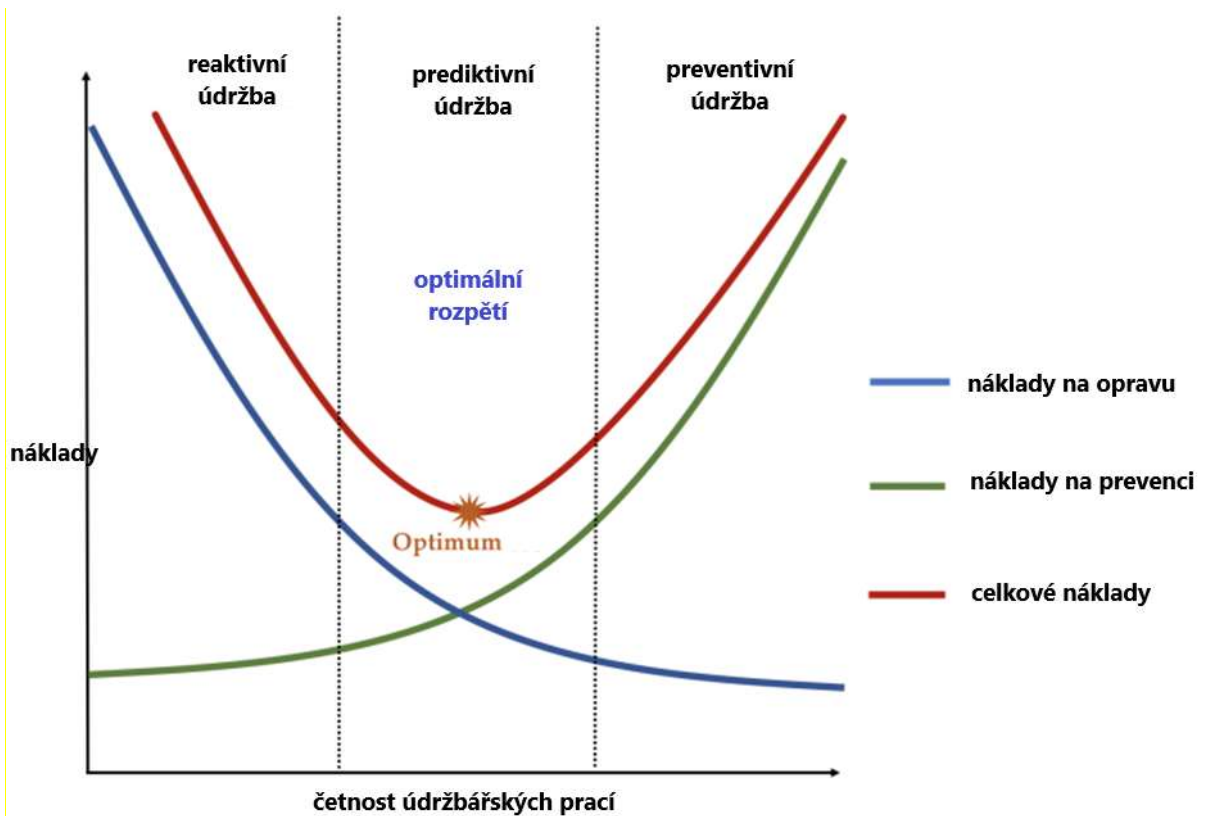
V roce 2002, (Grall, Bérenguer, & Dieulle, 2002) navrhl model pro výpočet nákladů pro prediktivní údržbu probíhající nepřetržitě s cílem nalézt optimální práh prevence. Objektivní funkce, která má být minimalizována představuje celkové očekávané náklady na dlouhodobou údržbu. Kumulativní náklady na údržbu lze vyjádřit jako:

$$C(t) = C_i \cdot N_i(t) + C_p \cdot N_p(t) + C_c \cdot N_c(t) + C_t \cdot d(t) \quad \text{[Kč]}$$

Rovnice 1 Kumulativní náklady na údržbu (Grall, Bérenguer, & Dieulle, 2002)

kde $N_i(t)$, $N_p(t)$ a $N_c(t)$ představují počet kontrol, preventivních oprav a oprav provedených v časovém intervalu $[0, t]$, zatímco $d(t)$ představuje trvání doby nečinnosti stroje v $[0, t]$.

V případě prediktivní údržby se proto činnosti údržby provádějí podle výsledků předpovědi možné poruchy, takže nákladový model je v tomto případě spojen s odhadem zbývajících životnosti konkrétního systému resp. zařízení. Vzájemný vztah je dobře popsán v (Arena, Collotta, Luca, Ruggieri, & Termine, 2021). Reaktivní údržba má nejnižší náklady na prevenci, zatímco preventivní má nejnižší náklady na opravu v důsledku dobře naplánovaných prostoju stroje. Namísto toho prediktivní údržba umožňuje dosáhnout nejlepšího kompromisu mezi náklady na opravu a náklady na prevenci 0.



Obrázek 1 Kompromis vztahu nákladů na opravdu a na prevenci (Arena, Collotta, Luca, Ruggieri, & Termine, 2021)

Prediktivní údržba prodlužuje životnost majetku a snižuje prostoje zařízení a náklady na náhradní díly a práci. Tento přístup také zvyšuje úroveň bezpečnosti pracovníků a optimalizuje provoz zařízení, což vede k okamžitým úsporám energie. Na druhé straně je třeba počítat s náklady na zřízení diagnostických zařízení (Arena, Collotta, Luca, Ruggieri, & Termine, 2021).

1.4 Prediktivní údržba

Prediktivní údržba je druhem údržby, který využívá různé prediktivní nástroje k určení časového rozvrhu potřebných jednotlivých činností, související s údržbou zařízení. Je založena na nepřetržitém monitorování integrity zařízení, což umožňuje provádět údržbu jen tehdy, když je to opravdu nutné. Kromě toho umožňuje včasnou detekci poruch díky prediktivním nástrojům založeným na historických údajích (například techniky strojového učení), faktorech integrity (například vizuální aspekty, opotřebenosti, zbarvení odlišné od originálu) a metodách statistické interference (Carvalho, Soares, & Vita, 2019). Dále popsal prediktivní údržbu jako nový typ údržby, která funguje na principu získávání reprezentativních vlastností monitorováním stavu zařízení a na základě toho předpovídá vývoj degradace.

Jak již bylo zmíněno v prvních podkapitolách, tak hlavním úkolem dobré strategie údržby je zlepšit stav zařízení, snížit míru selhání zařízení a minimalizovat náklady na údržbu a zároveň maximalizovat životnost zařízení. Díky této skutečnosti je strategie prediktivní údržby vhodnou volbou díky své schopnosti optimalizovat využití a řízení aktiv (Jezzini, Ayache, Elkhansa, Makki, & Zein, 2013) a (Kumar, Shankar, & Lakshman, 2018).

Prediktivní údržba se zabývá predikcí poruch dříve než k nim dojde. Podle (Jardine, Lin, & Banjevic, 2006), lze rozdělit metody údržby schopné monitorovat stav zařízení pro diagnostické a prognostické účely do tří hlavních kategorií a to:

- Statistické přístupy.
- Přístupy umělé inteligence.
- Přístupy založené na modelech.

Využívání jednotlivých postupů má svá pozitiva a také negativa. V případě metod založených na modelech je třeba mít mechanické znalosti a ovládat teorii zařízení, která mají být monitorována. Statistické přístupy vyžadují matematické znalosti zejména stochastických modelů, proto se je v praxi stále častěji využívána umělá inteligence. V roce 2018 (Baptista, 2018) porovnali umělou inteligenci se statistickými metodami, pozorovali převyšující výsledky ve prospěch umělé inteligence.

Jednou z metod umělé inteligence v prediktivní údržbě je strojové učení. Strojové učení (Machine Learning, ML) se ukázalo jako výkonný nástroj pro vývoj inteligentních prediktivních algoritmů v mnoha aplikacích. Přístupy ML mají schopnost zpracovat mnohorozměrné údaje ve velkém rozsahu a extrahovat skryté vztahy v rámci údajů ve složitých

a dynamických prostředích (jako jsou průmyslová prostředí) (Wuest, Weimer, Irgens, & Thoben, 2016).

Jednotlivé pokroky, internet a inovace vedly ke změně paradigmatu údržby. Právě inovativní technologie umožnila vytvoření celé škály nových funkcí a služeb. Senzory a digitalizované systémy řízení věcí minimalizují nepříjemnosti a spotřebu času související s údržbou (Carvalho, Soares, & Vita, 2019).

Prediktivní údržba představuje velmi složitý proces, který zobrazuje aktuální funkční stav a spolehlivost průmyslových strojů, zařízení či vozidel v reálném čase. Tato strategie údržby se rozvíjí ve čtyřech fázích (Lin, a další, 2019):

- Shromažďování údajů z různých senzorů systému.
- Předzpracování údajů.
- Diagnostika a prognóza poruch.
- Rozhodování o strategii údržby.

1.5 Typy prediktivní údržby

1.5.1 Fyzikální metody

Prvním způsobem prediktivní údržby je využití fyzikálních modelů. Fyzikální modely se využívají hlavně v oblastech monitorování například pobřežních turbín a námořních a vojenských systémů (Tinga & Loendersloot, 2019). Z matematického hlediska lze říci, že tento druh údržby koreluje s opotřebením životností komponentů. Mezi proměnnými však musí být zohledněny různé fyzikální veličiny, které popisují chemickou, mechanickou a elektrickou povahu daného zařízení.

Hlavní výhodou tohoto typu prediktivní údržby je, že prostřednictvím fyzikálního procesu dokáže přesně popsat výsledné výstupy. Negativními aspekty jsou složitost, vysoké náklady na implementaci a vysoká specifičnost systému, které poskytují menší možnost opětovného použití a rozšíření (Arena, Collotta, Luca, Ruggieri, & Termine, 2021).

1.5.2 Znalostní modely

Druhým způsobem prediktivní údržby je vytváření modelů založených na znalostech odborníků. Cílem tohoto způsobu je využít znalostí k vytvoření simulace dovedností a chování odborníků. Po formalizaci znalostí je možné je reprodukovat a automaticky aplikovat. Znalosti

jsou zpracovány externími systémy, které dokáží vyvodit závěrečné mechanismy na základě simulace myšlení odborníků v dané praxi.

Mezi nejběžnější přístupy k implementaci tohoto typu modelu patří systémy založené na pravidlech, neboť využívají jednoduchost při provádění a interpretovatelnosti. Nevýhodou je však jejich nízký výkon, zejména pokud je třeba vyjádřit komplikované podmínky nebo když je počet pravidel velmi vysoký (Arena, Collotta, Luca, Ruggieri, & Termine, 2021).

1.5.3 Metody založené na zpracování dat

Vzhledem k inovativnímu přístupu v průmyslu dochází k častějšímu využití systémů založených na získaných údajích s cílem dosáhnout efektivnějších řešení. V této části je představen nejnovější stav v oblasti přístupů založených na údajích, které lze získat využitím:

- Statistické přístupy.
- Stochastické přístupy.
- Techniky strojového učení.

1.5.4 Statistické a stochastické přístupy

Statistické a stochastické metody umožňují zabývat se složitými systémy, jejichž vývoj a změny nejsou snadno předvídatelné. Aplikace statistických metod pro určení prediktivní údržby může být výhodná v některých specifických případech souvisejících s provozem mechanických komponentů a vozidel (Saibannavar, Mallikarjun, & Kulkarni, 2020).

1.5.5 Strojová učení

Strojová učení je součástí umělé inteligence (AI) a zabývá se vytvářením systémů, které se učí a zlepšují výkon na základě vstupních údajů, které používají. V současnosti se používají čtyři typy algoritmů strojového učení:

- Algoritmy učení pod dohledem.
- Částečně kontrolované.
- Bez dozoru.
- Posilovací algoritmy učení.

Při učení bez dozoru nejsou údaje označeny a model je formulován tak, aby sám identifikoval vzory a struktury v údajích. V částečně kontrolovaném učení jsou vstupní údaje kombinací označených a neoznačených údajů. Při učení pod dohledem se používají označené

tréninkové údaje. Jinými slovy, vstupní proměnné a odpovídající výstup se dodávají do stroje, aby se naučili mapování ze vstupů na výstupy, přičemž se model často iterativně upravuje. Učení pod dohledem je pravděpodobně nejčastěji používaným strojovým učením. Využitím posilování učení umožňuje systému učit se podle pravidel, pokusů a omylů, aby objevil nejpříznivější akce.

1.5.6 Tradiční algoritmy

Nejpokročilejší metodou hlubokého učení, které se obvykle používají k prediktivní údržbě v automobilovém průmyslu, jsou tradiční algoritmy. Pojem hloubkové učení se vztahuje na podmnožinu umělé inteligence a strojového učení, která využívá vícevrstvé umělé neuronové sítě k odhadu lepší funkce mapování mezi konkrétními vstupy a výstupy. Využití algoritmů vyžaduje k dosažení vysoké přesnosti obrovské množství údajů. Tyto algoritmy se ve velké míře používají v mnoha automobilových odvětvích. Nejrozšířenější tradiční algoritmy používané při prediktivní údržbě jsou lineární regrese (LR), regrese Gaussova procesu (GPR), umělá neuronová síť (ANN), rozhodovací strom (DT), podpůrný vektorový stroj (SVM) a k-nejbližší sousedé (k-NN) (Arena, Collotta, Luca, Ruggieri, & Termine, 2021).

1.6 Metody plánování údržby vozidel používané v České republice

Na základě osobních konzultací v rámci odborných komisí Sdružení dopravních podniků ČR Odborné skupiny (OS) Tramvaje, OS Trolejbusy a OS Autobusy lze konstatovat, že postup při tvorbě plánů údržby vozidel je v rámci české republiky obdobný a postup je limitován právě zdrojovými daty pro plánování údržby a jejich strukturou. Není významný rozptyl mezi databázemi se zdrojovými daty ani strukturou plánů mezi jednotlivými dopravními podniky. Validace vytvořeného modelu v rámci této práce proběhne ve vybraném dopravním podniku dopravním podnikem ČR. Zasedání každé z odborných komisí Sdružení dopravních podniků ČR probíhá jednou ročně společně se zasedáními odborných komisí Sdružení provozovatelů hromadné dopravy osob v městských aglomeracích Slovenské republiky a na základě osobních konzultací lze konstatovat, že proces plánování údržby vozidel dopravních podniků na Slovensku probíhá zcela totožným způsobem.

Například jen v Ostravě realizoval dopravní podnik v rámci kalendářního roku 2021 na drážních trakcích (tramvaje a trolejbusy) 1.555 plánovaných prohlídek, 789 předsezónních prohlídek, 1.880 měsíčních prohlídek motorové části vozidel, 20.138 denních prohlídek a 543 neplánovaných oprav v důsledku havárií. V rámci autobusové trakce bylo realizováno 52.304

denních prohlídek, 1.308 kontrolních prohlídek, 39 středních prohlídek a 7 velkých prohlídek. Jediné prohlídky, které nejsou v provozu plánovány jsou velké prohlídky na tramvajové trakci. To je z důvodu, že pro velké prohlídky je již plně využit outsourcing z důvodu nedostatečných vnitřních kapacit pro jejich realizace. Velké prohlídky tramvají si dnes v praxi realizují jen 3 dopravní podniky ve městech: Praha, Brno, Liberec. Například Plzeňské městské dopravní podniky neprovádí interně údržbu žádnou, ale v modelu PPP je servis plně outsoursován. V pražském metru dokonce outsorsing údržby zašel tak daleko, že údržbu na každé lince metra realizuje jiná privátní společnost. Ať je údržba dělána v uvedených případech zcela interně nebo podléhá částečnému či plnému outsorsingu, tak potřeba plánování kapacit údržby a ekonomická predikce přímých nákladů je shodná (zasmluvnění jakékoli podoby outsorsingu samozřejmě plně odpovídá lokálním podmínkám).

V konečném důsledku je údržba vždy hrazena z veřejných prostředků a jen se liší instituce, která samotnou údržbu fyzicky vykonává. Způsob zasmluvnění údržby vozidel ale má dopady na procesy vyčíslení resp. predikce nákladů na provozování dopravy. Příklad outsorsingu údržby vozidel z Plzně je jediný, který nevyžaduje ze strany dopravního podniku žádné plánování údržby, protože dopravní podnik platí dodavateli pevnou taxu za najeté km a plánování údržby, ale i výpravy vozidel jsou plně v rukou dodavatelské společnosti. Ostatní dopravní podniky musí pro vyčíslení nákladů na budoucí provoz realizovat i plány údržby vozidel.

Stávající postup tvorby plánu údržby vozidel v České republice

Pro sestavení plánů údržby vozidel dopravních podniků existují v československém prostředí základní vstupy:

- Plán km.
- Předpis údržby pro jednotlivá vozidla.
- Karty vozidel.

Plán km

Plány km vychází z objednávek objednatelů dopravy, případně se jedná o dopravní výkony, které dopravce získal ve veřejné soutěži. Zpravidla je definice takových kilometrů v podobě popisu tras linek (jejich trajektorie, ze které je potřebná pouze její délka), počtu spojů případně i typů požadovaných vozidel. Pro celkové vyčíslení potřeby počtů vozidel

v jednotlivých depech a km připadajících na jednotlivá depa a typy vozidel je třeba sestavit i oběhy vozidel. Až z vytvořených oběhů vozidel se vytvoří plán km, Tabulka 1 reprezentuje příklad její podoby.

		Leden	únor	...	prosinec
Depo 1	typ vozidla 1	X km	X km		X km
	typ vozidla 2	X km	X km		X km
	...	X km	X km		X km
Depo 2	typ vozidla 1	X km	X km		X km
	typ vozidla 2	X km	X km		X km
	...	X km	X km		X km
...	...	X km	X km		X km

Tabulka 1 Plán km - příklad (autor)

Plány km jsou relativně dynamické zejména z důvodů výluk, případně z důvodů komerčních objednávek dopravy, odřeknutí výkonů ze strany objednatele (pandemie COVID 19, uzavření obsluhované zastávky / trasy linky).

Předpis údržby pro jednotlivá vozidla

Předpis údržby vozidel je primárně dodáván výrobcí vozidel. Tyto předpisy jsou pak agregovány do interních předpisů dopravních podniků. Předpisy prohlídek vozidel jsou vázány na najetou vzdálenost vozidel nebo na uplynulý čas od realizace poslední prohlídky. Zpravidla bývají interně označovány P1-P6, případně až P12 kdy vždy platí, že prohlídka s vyšším číslem je větší typ prohlídky, která je zároveň prohlídkou všech nižších prohlídek v číselné řadě (například realizace P3 je zároveň realizací P1 a P2). Mohou existovat i speciální prohlídky jako např. protipožární prohlídka (PZ) a další. Tabulka 2 zobrazuje příklad předpisu prohlídek pro typ vozidla. Jednotlivé vozy mohou mít v čase své vlastní předpisy. V praxi například u vozidel po vážných nehodách dochází ke zpřísnování kritérií jednotlivých prohlídek, nebo naopak u vozidel po záruce dochází k jejich navyšování. Stejně tak prohlídky závislé na čase nemusí být nutně prováděny u vozidel, která nejsou aktivně využívána (např. nemá smysl provádět pravidelnou měsíční protipožární kontrolu u vozidla, které se aktivně nepoužívá a jedná se o tzv. „železnou zásobu“). Mohou existovat i další lokální motivace k jejich změnám. Všechny změny tabulky předpisů by ale měly být prováděny v souladu platnou legislativou dané země.

Typ prohlídky	Vzdálenostní limit [km]	Časový limit [d]	Tolerance
PZ	-	30	±5
P1	20 000	-	±500
P2	20 000	-	±500
...			
P12	-	365	±30

Tabulka 2 Předpis plánované údržby – příklad (autor)

Rozsah jednotlivých prohlídek (plánované údržbě) vozidel resp. úkony, které se musí v rámci dané prohlídky realizovat, nejsou pro tuto disertační práci relevantní.

Pro jednotlivé typy prohlídek (plánované údržbě) vozidel jsou přímo předepsány typy dílů, které musí být povinně vyměněny a kontrolovány. Záznamy o provedených výměnách náhradních dílů jsou zaznamenány na kartě vozidla příp. je možné je dohledat až k výdejce ze skladu.

Tabulky předpisů prohlídek jsou relativně statické a k jejich manuálním změnám dochází výjimečně. Z pohledu své struktury jsou shodné pro vozidla všech trakcí.

Karty vozidel

Každé vozidlo má svou kartu, zpravidla elektronickou. Karta vozidla obsahuje informace o najetých kilometrech, provedené plánované i neplánované údržbě a zpravidla je dohledatelná vazba na výdejku ze skladu o spotřebě náhradních dílů provedené při dané údržbě.

Karty vozidel představují nejdynamičtější vstup pro plánování údržby, protože zejména najeté km se za každý den mohou lišit o stovky až tisíce a denně probíhají jednotky až desítky pravidelných prohlídek.

Jak bylo uvedeno v příkladech v kapitole 1.6, tak během jednoho kalendářního roku dochází k realizaci tisíců plánovaných prohlídek. Část z nich je závislá na čase, část z nich je závislá na najetých km jednotlivých vozidel. Neplánovaná údržba a údržba z důvodů nehod je logicky závislá opět jen na najetých km jednotlivých vozidel (pokud se pominou např. situace, kdy dojde k posprejování nepoužívaného vozidla po vniknutí do přímo do depa a následně jeho mytí resp. neplánované údržbě).

Je tedy zcela zřejmé, že plán km je zcela stěžejní pro sestavu plánu údržby i odhadu neplánované údržby a nákladů na opravu vozidel po nehodách. Úkolem managementu dopravního podniku je v co možná nejkratším čase finančně i provozně kvantifikovat celkové náklady na údržbu na budoucí období, aby bylo možné v rámci jednání s objednatelem dopravy vyčíslit náklady na objednanou dopravu a zajistit tak její zasloužení.

Jak bylo uvedeno výše, tak jen sestava plánu km je časově náročný proces, jelikož obnáší kompletní tvorbu oběhů vozidel zaměstnanci dopravního podniku a plán údržby vozidel na něj teprve navazuje. Celý proces zpravidla komplikuje například nejistota při pořizování nových vozidel (termíny a rozsah dodávek).

Menší dopravní podniky ve městech jako Jihlava, Chomutov + Jirkov, Most + Litvínov atd. které mají vzhledem ke svému charakteru řadu let statický plán km a vozový park se obnovuje v delších časových intervalech, využívají v praxi znalostní modely. V praxi mohou v roce t_0 použít plány a zkušenosti z již realizovaného roku t_{-1} , jen započítat inflaci a plán údržby i s plným vyčíslením nákladů mají hotový pro rok t_{+1} s velmi vysokou přesností v řádu jednotek dní. Do této skupiny dopravních podniků ale mohou spadat i ty s větším provozem, pokud je jejich provoz meziročně relativně statický. Např. Pardubice a Olomouc střídají víceletá období „klidnější“ s obdobími významných změn v plánech km i skladbě vozového parku.

Pro větší dopravní podniky jako Ústí nad Labem, Liberec, Plzeň, Ostrava atd., kde mezi lety t_{-1} a t_{+1} dochází k významným změnám plánů km a složení vozového parku, celý proces trvá za pomoci znalostních metod i řadu měsíců pro management s desítkami let zkušeností.

Plány údržby jsou pak managementem dep v denní frekvenci aktualizovány podle změn v plánu km, kartách vozidel. Tato každodenní aktualizace znamená hodiny manuální práce pro manažera depa. Jediný SW nástroj, který je pro tvorbu plánů údržby a vyčíslení nákladů využíván, je tabulkový procesor MS Excel. Jeho reálné využití lze nazvat degenerací využití metod založených na zpracování dat. Specializované SW na management dep a skladového hospodářství slouží výhradně k evidenci minulosti, nikoli automatizaci tvorby plánů údržby.

1.7 Shrnutí aktuálního stavu plánování údržby

Každá z metod uvedená v kapitole 1.5 má historicky své uplatnění pro specifické případy a primárně se liší v tom, jaká data a v jaké kvalitě jsou potřeba pro jejich aplikaci.

Fyzikální metody nevyžadují viz 1.5.1 pro svou aplikaci žádná data a samy o sobě vůbec nepomáhají při tvorbě plánů údržby vozidel. Jsou vhodné jen jako doplňkové a v praxi se využívají jako součást všech typů údržby, kdy kvalifikovaní pracovníci provádí kontroly, na které jsou školeny přímo dodavateli dopravních prostředků.

Znalostní modely viz. 1.5.2 jsou jedinou dnes v československém prostředí využívanou metodou a na větších dopravních podnicích se plně projevuje nevýhoda v její velké časové náročnosti. Vzhledem časovému tlaku na management dopravních podniků pak klesá i spolehlivost této metody.

Metody strojového učení viz. 1.5.5 jsou velmi rychlé a vysoce efektivní a nemají problém s dynamičností vstupních dat. Pro vytvoření těchto metod je ale potřeba široká datová základna (maximální historie) bez faktických chyb v datové základně a zároveň je v československém prostředí vysoký tlak na jejich ovládnutí (maximální vstupy kvalifikovaného managementu). Československé prostředí tedy nespĺňuje zejména požadavek na širokou datovou základnu bez faktických chyb a chování metod strojového učení se obtížně kontroluje a ovládá. Vytvoření a ovládnutí metod strojového učení vyžaduje specialistu na umělou inteligenci, nikoli manažera dopravního podniku.

Metody založené na zpracování dat viz. 1.5.3 a statistické a stochastické přístupy viz. 1.5.4 se dobře ovládají i kontrolují. Reálně je jejich chování také citlivé na kvalitu vstupních dat, stejně jako metody strojového učení. Jelikož se jejich chování snadno kontroluje, tak se v praxi anomální chování zpravidla vysvětlí chybou ve vstupních datech a iterativně tak lze data opravovat (standardně se v datové analytice používá termín „čistit“) jen ze strany uživatelů systému. Jelikož chování těchto modelů je ve své podstatě stochastické, tak detekce chyb v datech není zcela jednoznačná jen z pohledu na výstupy systému. Kvalifikovaný uživatel, který má přehled o zdrojových datových strukturách a běžných hodnotách je ale schopen chyby v datech rychle odhalovat. Nevýhodou těchto přístupů je, že v případě významné změny v datech, na kterých byly tyto modely kalibrovány, je třeba tyto modely upravit. Takovými změnami může být v případě plánů údržby např. zcela nový typ vozidla (např. na vodíkový pohon), který by měl odlišná kritéria na realizaci plánované údržby.

Tradiční algoritmy viz. 1.5.6 se dobře ovládají i kontrolují. Stejně jako metody založené na zpracování dat viz. a statistické a stochastické přístupy jsou citlivé na vstupní data, ale na

rozdíl od nich je vyžadována vyšší míra porozumění algoritmu uživatele na detekci příčiny resp. chyby v datech. Detekce chyb je ovšem vždy zcela jednoznačná.

Obrázek 2 zobrazuje mapu datových zdrojů, které mohou být využity pro jednotlivé kroky ve výše uvedených algoritmech. Datové zdroje jsou v prvním sloupci rozděleny na databázové a zdroje, které vznikají mimo databázové systémy dopravců, resp. nejsou systémově podchyceny ve zdrojových systémech. V dalším sloupečku jsou uvedeny business názvy datových zdrojů. Červeně jsou označeny proměnné s nízkou spolehlivostí na zdrojových systémech (doba údržby) nebo vysokou proměnlivostí na straně vstupů algoritmu (počet potřebných vozů daného typu na den a předpokládané km). Oranžovou barvou jsou zvýrazněna data, která budou již tvořena algoritmicky a případně budou dále upravována uživatelem resp. manažerem, který má na starosti plánování údržby vozidel. Data jsou zde rozdělena do sekcí „Databáze“ a „Ručně“ z toho důvodu, že autor práce předpokládá využití modelu v praxi a z hlediska praktického využití je třeba uvažovat i o možnostech inženýrského propojení modelu do ekosystému softwarových nástrojů dopravních podniků. Využití konkrétních metod při tvorbě plánu údržby vyžaduje již návrhovou část alespoň na úrovni pseudoalgoritmu, proto Obrázek 2 nezobrazuje přímé užití metod a ta bude součástí až disertační práce.

Databáze	Trakce [d]
	Typ vozu [d]
	Stav vozu [d]
	Typ údržby daného vozu [d]
	Doba údržby ? [] pravidelná - smlouva ano/data?
	Nepravidelné - zkusit odvodit
	km limit s rezervou [d]
	Datum a typ minulé údržby [?]
	Historie denních proběhů [d]
	Historie doby údržby [?]
	Historie cen údržby [?]
	Budget pro údržbu [d]
	Aktuální čerpání budgetu pro údržbu [?]
	Počet potřebných vozů daného typu na den? [?]
	Předpokládané km [?]
	Km koeficient vozu [Q]
Ručně	Distribuované km [d]
	Vysoutěžené ceny [6m]
	Inflace [6m]
	Soubor speciálních technik [jednou]
	Rezerva km limitu [on demand]
Denní kapacita údržby [on demand]	
Nový typ vozu [on demand]	

Obrázek 2 Existující a neexistující datové zdroje (autor)

2 CÍL DISERTAČNÍ PRÁCE

Mezi nejvíce využívané typy údržby v dopravním podniku provozujícím městskou hromadnou dopravu se zařazuje plánovaná údržba, neplánovaná údržba a údržba po nehodě. Hlavním problémem zmíněné údržby na našem území je limitace informací o plánovaných výkonech jednotlivých vozidel, a tedy obtížná odhadnutelnost rozsahu plánované i neplánované údržby jednotlivých vozidel a vyčíslení budoucích finančních nákladů.

Tato disertační práce se zaměřuje na procesy plánování údržby vozidel dopravních podniků a její typy realizované dle zvyklostí v československém prostředí. Hlavním cílem této práce je vytvoření prediktivního plánu údržby vozidel dopravního podniku, který by zajistil zpřesnění plánování údržby, a tedy i nákladů její realizaci. Veškeré modely a výpočetní procesy mají být manažersky ovladatelné alespoň v rozsahu:

- Ruční korekce predikovaných nákladů (např. při změně smluv, inflace apod.)
- Ruční korekce využití vozového parku (plán vyřazování vozidel a nákup nových)
- Ruční korekce plánu najetých km jednotlivých provozů a dep/vozoven

Takto ovladatelný systém na tvorbu plánů údržby pak má být využitelný i pro modelování hypotetických situací a rychlého vyhodnocování budoucích nákladů na údržbu vozového parku dopravního podniku. Plnění hlavního cíle práce je spojeno s plněním dílčích cílů a to:

- Vytvořit vstupy pro funkční plán skladových zásob zabezpečující z pohledu dopravce optimální spolehlivost údržby vozidel
- Vytvořit funkční nástroj plánování preventivní údržby závislé na ujetých kilometrech
- Vytvořit model predikce založený na kombinaci stochastických a klasických metod
- Vytvořit model predikce nákladů založený na historii nákladů ve vztahu k vozovému parku

3 PŘEHLED METOD POUŽITÝCH K DOSAŽENÍ CÍLE PRÁCE

V této části autor shrnuje základní metody pro dosažení cílů disertační práce. Nejprve s metodami spíše teoretickými, jako analýza stávajícího procesu, model procesu a simulace, pokračují metody čistě matematické jako predikce časových řad nebo Poissonova regrese, a nakonec jsou uvedeny metody praktické jako je využití case study.

3.1 Analýza stávajícího procesu

Procesem dle (Hammer & Hershman, 2010) se rozumí soubor činností, který vyžaduje jeden nebo více druhů vstupů a tvoří výstup, který má hodnotu pro zákazníka. Analýza spočívá dle (Hendl, 2008) v rozdělení celku na jeho komponenty a dále na zkoumání, jak tyto komponenty fungují jako samostatné prvky a jaké jsou mezi nimi vztahy.

V rámci analýzy stávajícího procesu se tedy dělí proces na jeho jednotlivé komponenty a zkoumají se vztahy mezi nimi, a také jejich vztahy ke vstupům a výstupům procesu.

3.1.1 Predikce časových řad

Časovou řadou dle (Chatfield, 2000) se rozumí série časově uspořádaných dat či pozorování. Z hlediska řešitelnosti úlohy predikce časové řady se nejčastěji užívají ekvidistantní časové řady, které mají mezi jednotlivými pozorováními stejnou časovou prodlevu.

Časové řady budou v této disertační práci primárně určeny k predikci cen, protože na vývoj ceny v čase lze pohlížet jako na časovou řadu. Použití statistických modelů pro analýzu a predikci časových řad se datuje již do první poloviny dvacátého století. Již v 70. letech dvacátého století existovala celá škála metod pro predikci ceny (Chambers, Mullick, & Smith, 1971). Standardní statistické modely pro analýzu a predikci časových řad shrnuje např. (Chatfield, 2000). Evaluací těchto metod se zabývá (Armstrong, 2001) ale fyzicky v něm nejsou samotné metody predikce, jen způsoby, jak je evaluovat.

(Dama & Sinoquet, 2021) již poskytnut přehled standardních statistických modelů doplněný o 6 kategorií neuronových sítí vhodných pro analýzu a predikci časových řad.

Standardní statistické modely pro analýzu a predikci časových řad zahrnují model s exponenciálním vyhlazováním od (Everette S. Gardner & Mckenzie, 1985), model s lokálním

polynomiálním vyhlazováním dle (Fan & Gijbels, 2018), autoregresní model od (Yule, 1927), metoda klouzavého průměru řešená v (Whittle, 1953), ARMA model zahrnující jak autoregresi tak klouzavý průměr dle reprintu originálního článku z roku 1970 v (Box P., 2016), dále pak ARIMA model z (Kinney, 1978) rozšiřující model ARMA o integrační člen, případně SARIMA model dle (Persaud, 1980), který navíc modeluje sezónnost. Dále pak aditivní Holt-Wintersova metoda z článků (Winters, 1960), (Holt, 2004), což je reprint článku z roku 1957, a mnohé další. Z novějších modelů odvozených od modelu ARIMA se jedná například o model ARFIMA (Pandher, Hossain, Budsaba, & Volodin, 2022). Význam a princip základních částí modelů ARIMA:

- Autoregrese (AR): Tato část modelu využívá závislosti mezi pozorováním a několika zpožděnými pozorováními (předchozími časovými body).
- Integrovaná (I): V tomto případě dochází k diferencování pozorování, aby se časová řada stala stacionární, což znamená, že statistické vlastnosti řady se v čase nemění.
- Klouzavý průměr (MA): Tato část modeluje závislost mezi pozorováním a reziduální chybou z modelu klouzavého průměru aplikovaného na zpožděná pozorování.

Modely ARIMA a z něho odvozené jsou všestranným, výkonným a ovladatelným nástrojem pro předpovídání časových řad, který lze použít v různých oblastech, jako je řízení dodavatelských řetězců, předpovídání spotřeby el. energie, analýza finančních trhů a další. Díky své schopnosti pracovat se stacionárními i nestacionárními daty a dostupnému zpracování (Python, R apod.) jsou často užívanými modely pro úlohy predikčního modelování.

Za posledních 20 let se výrazně rozvinulo využití neuronových sítí pro predikci časových řad. Přehled metod pro analýzu a predikci časových řad pomocí neuronových sítí shrnuje (Tealab, 2018), ze samotných metod pak např. nelineární model s perturbacemi (Pang, Guo, Xiong, & Li, 2007), hybridní přístupy kombinující ARIMA metodu s neuronovými sítěmi (Zhang, 2003) a (Wang & Syntetos, 2011), přístup kombinující fuzzy regresní model s neuronovými sítěmi (Khashei, Hejazi, & Bijari, 2008), či přístup kombinující Markovův model s neuronovými sítěmi a genetickými algoritmy (Alalawin, Arabiyat, Alalaween, Qamar, & Mukattash, 2021). Stejně tak se (Alalawin, Arabiyat, Alalaween, Qamar, & Mukattash, 2021) zabývá predikcí potřeby skladových zásob spolu s jejich cenou pomocí několikanásobné lineární regrese.

3.1.2 Model procesu a simulace

Zjednodušeným zápisem výsledku analýzy procesu je model procesu. Jinak řečeno, model procesu je zjednodušený popis procesu a jeho chování. V namodelovaném procesu je možné zkoumat jeho chování vzhledem ke zvoleným podmínkám pomocí simulace.

V daném případě bude model procesu zvolen pro tvorbu samotného plánu údržby. Základní shrnutí poskytují např. (Basri, Abdul Razak, Ab-Samat, & Kamaruddin, 2017) a (Garg & Deshmukh, 2006). Většina metod vychází z popisu úlohy s využitím lineárního programování, některé metody pak tvoří plán za použití genetických algoritmů nebo jiných stochastických metod. Pomocí lineárního programování modelují úlohu plánování údržby (Mira, Andrade, & Gomes, 2020) (Haghani & Shafahi, 2002). Další klasickou metodou plánování údržby je pomocí metodologie P-graf (Adonyi, Heckl, & Olti, 2013), kterou lze řešit i multiagentním systémem (Zhou, Fox, Lee, & Nee, 2004).

3.1.3 Modely pro predikci skladových zásob

Cílem této práce není i samotná predikce skladových zásob, ale vytvoření podkladů pro jejich predikci. Proto je třeba udělat alespoň základní přehled metod predikce skladových zásob, aby bylo zřejmé, jaká data mají modely predikce poruch poskytovat.

V posledních padesáti letech se predikci poptávky po skladových zásobách či náhradních dílech věnuje značná pozornost, a to zvláště kvůli nalezení optimálního kompromisu mezi jejich dostupností a cenou za jejich držení a skladování. Tato sekce většinou vychází z kritického přehledu současné literatury poskytnutého (Pinçe, Turrini, & Meissner, 2021) a (Syntetos & Boylan, 2001).

Metody pro predikci potřeby skladových zásob lze rozdělit na metody využívající časové řady a neuronové sítě, a metody využívající kontext predikce, zvláště pak životní cyklus, plán údržby, stáří a provozní podmínky daného zařízení či procesu, pro který jsou náhradní díly či skladové zásoby využívány.

V základu se jedná o využití časových řad obdobně jako v 3.1.1, specificky pro predikci potřeby skladových zásob jsou využity např. Crostonova metoda (Croston, 1972), metoda SBA (Syntetos & Boylan, 2001) nebo využití bootstrappingu (Willemain, Smart, & Schwarz, 2004) (Varghese & Rossetti, 2008). Další možností je Bayesovský model využívaný pro predikci potřeby skladových zásob (Apak, 2012).

Vedle časových řad lze využít i stochastický model spotřeby náhradních dílů pomocí Poissonova rozdělení pro určení optimálních parametrů daného systému zásob (Xinmin, Wei, & Huizhi, 2016). V případě cílení na just-in-time dostupnost náhradních dílů pomocí systému pro monitorování stavu, je třeba správu náhradních dílů zajišťovat např. modelem proporcionálních rizik (Lelo, Heyns, & Wannenburg, 2020).

Pro predikci skladových zásob lze využít i neuronových sítí (Gutierrez, Solis, & Mukhopadhyay, 2008) (Lolli, a další, 2017) přičemž jejich srovnáním s klasickými metodami se věnuje (Mukhopadhyay, Solis, & Gutierrez, 2012).

Jednou z metod predikce potřeby skladových zásob s využitím kontextu predikce je např. dvoufázová prediktivní metoda (Romeijnders, Teunter, & Jaarsveld, 2012), která modeluje jak množství potřebných součástí pro danou opravu, tak samotný počet oprav. Díky tomu umí tato metoda využít informace ohledně plánovaných oprav, čímž se autorům povedlo snížit chybu modelu až o 20% v porovnání s modely, které s informacemi ohledně plánovaných oprav nepracovaly.

Dalšími metodami v této kategorii jsou metody které v sobě začleňují také úsudek experta (Van den Broeke, De Baets, Vereecke, Baecke, & Vanderheyden, 2019) (Fildes & Goodwin, 2007), které v přehledu srovnává (Arvan, Fahimnia, Reisi, & Siemsen, 2019).

3.1.4 Poissonova regrese

Poissonova regrese je jednou z metod predikce časových řad, a to na základě poissonovy distribuce:

$$P(x) = \frac{e^{-\lambda} \lambda^x}{x!} \quad [-1]$$

Rovnice 2 Poissonova distribuce

Poissonovým modelem s parametrem λ se v praxi popisují data vzniklá jako počet výskytů sledované události za jednotku času, přičemž jednotlivé události jsou na sobě nezávislé a jejich průměrný výskyt za jednotku času je λ .

3.2 Případová studie

Případová studie viz. (Yin, 2017), je podrobná studie konkrétního předmětu, která je vedena za účelem lepšího pochopení daného jevu. Existuje více různých možností provedení

případové studie a její nastavení a parametry se liší především podle oboru, ve kterém je použita a jejího cíle. Proto v této části autor popisuje návrh případové studie, která bude použita pro aplikaci metody navržené v této disertační práci v kontextu reálného světa.

Formálně se případová studie skládá z několika částí. Začíná úvodem, který popisuje rozsah a účel studie, tedy cíl. Dále následuje část metod, ve které jsou popsány metody použité v rámci případové studie. Hlavní zjištění případové studie jsou obsažena v diskuzní části. V daném případě se bude diskutovat o implementaci navrhované metody v kontextu reálného světa.

Nakonec v závěrečné části dochází ke shrnutí zjištění.

Jsou-li k dispozici výsledky případové studie, je třeba mít vždy na paměti, že výsledek jednoho případu může být způsoben náhodnou poruchou nebo chybou.

3.3 Metody praktické

Čištění dat

Čištění dat (anglicky Data Cleansing) je proces oprav, úprav a mazání dat, která jsou nesprávná, neúplná nebo duplikovaná. Čištění může být jednorázové nebo může být prováděno průběžně. Stejně tak jej lze dělat buď ručně nebo prostřednictvím různých softwarových nástrojů.

4 POSTUP PREDIKTIVNÍHO PLÁNOVÁNÍ ÚDRŽBY VOZIDEL

Autorem navrhovaný postup při tvorbě prediktivního plánu údržby vozidel tvoří široký systém. Navržený postup musí respektovat aktuální stav datových zdrojů využitelných pro plánování údržby popsaný v kapitole 1.7 a vedle postupu a algoritmů pro řešení jednotlivých kroků jsou navržena i nutná rozšíření aktuální datové základny.

V následujících kapitolách jsou popsány okruhy:

- předpoklady pro zvolený postup,
- opomíjené podmínky,
- datové zdroje, včetně návržení nových a kontrolních,
- navrhovaný postup plánování údržby s využitím nových datových zdrojů
- a algoritmy pro řešení jednotlivých kroků.

4.1 Předpoklady návrhu postupu a algoritmů

V kapitole 1.6 je shrnut současný postup používaný v československém prostředí pro plánování údržby vozidel v dopravních podnicích provozujících městskou hromadnou dopravu. Z uvedeného vyplývá, že při návrhu celého postupu využívající algoritmické zpracování je třeba brát v úvahu následující omezení a podmínky:

- Dopravní podniky disponují kvalifikovanými pracovníky pro ruční zpracování plánů údržby vozidel.
- Zejména kvalifikovaní pracovníci, kteří by měli být cílovými uživateli navrženého postupu a algoritmů, mají vysoké nároky na ovládání a kontrolu celého systému.
- Je třeba zpřesnit predikce výkonů jednotlivých typů vozidel.
- Je třeba predikovat výkony pro jednotlivá vozidla.
- Předpisy údržby jsou stanovené pro typy vozidel.
- Jednotlivé vozy mohou mít vlastní předpisy údržby.

- Každé vozidlo má svou elektronickou kartu vozidla obsahující:
 - historii výkonů,
 - provedenou plánovanou
 - a provedenou neplánovanou údržbu.
- Datová základna viz. všechny datové zdroje uvedené na Obrázek 2 není z historických a praktických důvodů očištěna o chyby a nepřesnosti.

4.2 Opomíjené podmínky

Existuje množina podmínek, které by měl obecně postup pro plánování údržby vozidel zohledňovat, ale z praktických důvodů nejsou pro československé prostředí relevantní.

Ačkoli se jedná o podmínky, které nejsou samy o sobě v navrhovaném postupu a algoritmech zohledněny, tak u jednotlivých algoritmů a kroků postupu je upozorněno na to, že právě v daném algoritmu či postupu by bylo vhodné danou podmínku zohlednit.

4.2.1 Kapacity zdrojů pro provádění plánované i neplánované údržby

Kapacity zdrojů pro provádění plánované i neplánované údržby představují lidské zdroje a plochy pro provádění plánované a neplánované údržby.

V československém prostředí, jak bylo uvedeno v kapitole 1.6, nepředstavuje omezení výše uvedených zdrojů reálný problém pro všechny druhy prohlídek a údržby s výjimkou velkých prohlídek pro kolejová vozidla, které v této disertační práci odpovídá označení P1. Jelikož v rámci velké prohlídky kolejových vozidel dochází na odstavné koleji takřka ke kompletnímu rozebrání vozidel, tak prohlídky P1 znamenají:

- významnou časovou náročnost
- a vysokou rizikovost jakéhokoli časového odhadu realizace.

Časová náročnost velké prohlídky kolejových vozidel převyšuje jeden kalendářní den.

Rizikovost velké prohlídky kolejových vozidel spočívá v tom, že v jejich průběhu dochází k detekci poruch a závad a často vzniká potřeba užití náhradních dílů. Potřebné náhradní díly nemusí být vždy u dopravního podniku skladem a čekací lhůty na jejich dodání

často převyšují i tři měsíce. Po tuto čekací dobu je pak reálně kolejové vozidlo, případně celá souprava, v rozmontovaném stavu odstavena na koleji, která je určena pro servis a tato kolej pak není dostupná pro prohlídky a servis jiných vozidel.

Pro výše uvedené důvody se velké prohlídky kolejových vozidel v případě interní realizace nebo i outsorsingu domlouvají jen s krátkým předstihem podle volných kapacit a na roční období se reálně odhaduje jen jejich počet.

4.2.2 Obsluhované spoje a linky

Je logickým předpokladem, že potřeba zejména neplánované údržby, která vzniká v důsledku poruch či jejich očekávání, primárně přímým opotřebením vozu a jeho částí, je závislá na tom, jaké území obsluhuje. V praxi jiné opotřebení různých částí vozidel vzniká u vozidel, které jsou nasazeny na spoje, kde musí překonávat větší převýšení nebo jsou jinak více zatíženy např. vyšším počtem cestujících. Stejně tak pro nehody je logické předpokládat, že existují na obsluhovaném území místa s vyšší a nižší mírou rizika nehod. Jakýkoli navrhovaný postup a model by tak logicky měl zohledňovat i to, jaké konkrétní spoje obsluhuje a jaké opotřebenění a rizik na nich tedy vzniká.

V praxi plány km, které jsou uvedeny v kapitole 1.6, vznikají na jednotlivé typy vozidel. A zároveň platí, že dopravní podniky se snaží mít maximálně homogenní vozový park, právě z důvodu údržby a celkových nákladů na údržbu a udržování skladových zásob.

Dopravní podniky si různé typy vozidel pořizují právě z důvodu obsluhy území, resp. linek a spojů, které mají nestandardní podmínky. Např. v Liberci existuje skupina autobusů dopravního podniku, které jsou nasazovány na linky do Bedřichova. Tyto autobusy překonávají největší výškové převýšení, stoupání a jezdí maximálně zatíženi v zimním období, tedy jsou na ně kladeny ty největší nároky z pohledu výkonu a údržby. Tato skupina vozidel logicky není nasazována na jiné linky. Stejně tak např. v Praze je izolovaná skupina vozidel využívána např. pro linku spojující zoologickou zahradu a sídliště Bohnice, která ve většině své délky překonává významné stoupání/klesání. Obdobná situace panuje i v jiných městech v československém prostoru.

Pro výše uvedené důvody kombinace vstupních dat:

- plán km na typy vozidel
- a karta vozu,

tedy plně postihuje situace, ve kterých v praxi dochází k různému zatížení vozidel v důsledku jejich nasazení na různé linky a spoje.

4.2.3 Heterogenní vozový park

Potřeba plánované údržby vozidel různého typu jsou samostatně definovány v předpisech údržby. Je ale logickým předpokladem, že potřeba neplánované údržby, která vzniká v důsledku poruch či jejich očekávání, primárně přímým opotřebením vozu a jeho částí, je závislá na tom, o jaký se jedná typ vozu. Existují významné rozdíly mezi vozy zejména s ohledem na druh pohonu (nafta, CNG, baterie, vodík). V praxi, jedná-li se o opravdu významné rozdíly, jsou tyto kategorie rozlišeny již v plánech km, které jsou uvedeny v Tabulka 1. Uvedené kategorie mají totiž různé kapacity (midibusy, minibusy, kloubové autobusy, soupravy) nebo dojezdové vzdálenosti, jsou jiným způsobem vázány na infrastrukturu, např. kvůli nabíjení a doplňování pohonných hmot, a proto už v rámci plánování jízdních řádů a oběhů vozidel dochází k jejich odlišování.

V rámci této práce se tedy vychází z logického předpokladu, že odlišení kategorií vozidel významné z provozních důvodů, je shodné s odlišením kategorií vozidel s obdobnými potřebami neplánované údržby.

4.3 Datové zdroje

Jak bylo uvedeno v kapitole 1.7, tak v současné době existují dostupné databázové zdroje dat, jiné existují jen v papírové podobě a nejsou systémově uchopeny. Pro proces plánování údržby však mají význam a musí existovat ve zpracovatelné podobě. V obrázku Obrázek 3 je znázorněna mapa využití datových zdrojů přímo na procesy navržené v kapitole 4.4. Jejich popis a sjednocení do zjednodušujících datových objektů je uveden dále.

		Km koeficient vozu [Q]	Distribuce km [d]	Predikce cen PL údržby dle typu [on demand]	Predikce cen ostatní údržby [on demand]	Doba opravy/údržby [on demand]	Zobrazení v plánu [d]	
Databáze	Trakce [d]	✓	✓	✓	✓	✓	✓	
	Typ vozu [d]	✓	✓	✓		✓	✓	
	Stav vozu [d]		✓				✓	
	Typ údržby daného vozu [d]			✓			✓	
	Doba údržby ? [] pravidelná - smlouva ano/data?		✓			✓		
	Nepřavidelné - zkusit odvodit							
	km limit s rezervou [d]						✓	
	Datum a typ minulých údržby [?]						✓	
	Historie denních proběhů [d]	✓						
	Historie doby údržby [?]	✓				✓		
	Historie cen údržby [?]			✓	✓			
	Budget pro údržbu [d]						✓	
	Aktuální čerpání budgetu pro údržbu [?]						✓	
	Počet potřebných vozů daného typu na den? [?]						✓	
	Předpokládané km [?]		✓				✓	
	Km koeficient vozu [Q]	✓	✓				✓	
	Distribované km [d]						✓	
	Ručně	Vysoutěžené ceny [6m]			✓			✓
		Inflace [6m]			✓	✓		✓
		Soubor speciálních technik [jednou]						✓
Rezerva km limitu [on demand]								
Denní kapacita údržby [on demand]							✓	
Nový typ vozu [on demand]						✓		

Obrázek 3 Mapa užití datových zdrojů (autor)

4.3.1 Existující datové zdroje

Pro návrh celého procesu dochází ke schematickému zjednodušení existujících datových zdrojů v následující podobě:

- Historie údržby (hitorie_uzrby) – obsahuje historii provedené údržby pro každé konkrétní vozidlo a její typ a účel, dále historii stavů vozů.
- Základní údaje o vozu (vuz_hlavicka) – obsahuje trakci, typ vozu, identifikaci (SPZ, číslo vozu atd.), pohon, používané palivo.
- Ceny za provedené údržby a opravy (pp_cena) – obsahuje seznam spotřebovaného materiálu a práce pro každou prohlídku a opravu.
- Dopravní výkony vozidel (km_denni_pribl) – obsahuje denní najeté km pro každé vozidlo. Jelikož vozy jsou v provozu i přes noc a historicky se jednalo o přepis z papírových dokumentů a tachometrů, tak se jedná jen o přibližné údaje.
- Předpis údržby (limit_vuz_orig) – předpis údržby od výrobce.

- Plán velké údržby kolejových vozidel (tramvaj_SPVP) – plán velkých prohlídek kolejových vozidel.

4.3.2 Nově definované datové zdroje

Oproti existujícím databázovým zdrojům dat se zavádí nové:

- Plán km (plan_km) – obsahuje data o plánech km popsanych v kapitole 1.7.
- Mapa číselníků typů vozů (ciselnik_typ_vozu) – reálně slouží jen pro spárování dat konstruktérů grafikonů, kteří vytváření plány km pro zpravidla obecné typy vozidel (např. „kloubový autobus“), s reálnými typy vozidel v vuz_hlavicka (kloubových autobusů může být více typů).
- Plán likvidace vozidel (plan_likvidace) – Seznam vyřazovaných vozidel s plánovaným datem likvidace.
- Seznam nových vozů (novy_vuz_hlavicka) – Stejná struktura jako vuz_hlavicka, ale pro vozidla neexistující. Slouží pro modelování situací „kdybychom si pořídili konkrétní vozy v konkrétním období“.
- Předpis údržby nově pořizovaných/zamýšlených vozidel (novy_vuz_prohlidka) - předpis údržby od výrobce.
- Rezervy předpisů údržby (rezerva_limitu) – Seznam předepsaných údržeb a dopravním podnikem tolerovaný limit jejich provedení v %.
- Využití rezervy (vyuziti_rezervy) – proměnná ANO/NE, zda chce dopravní podnik využít rezervu v rezerva_limitu.

4.3.3 Editovatelné průběžné výsledky

Jedním z požadavků na celý systém je jeho říditelnost uživatelem. Z tohoto důvodu autor práce definuje následující datové sady:

- Kilometrový koeficient (km_koeficient) – reprezentuje váhu vozu v systému.
- Výsledný plán km (plan_km_vysledny) – plán km distribuovaný na konkrétní typy vozidel

- Odhad cen (odhad_cen) – odhad cen jednotlivých typů údržby pro konkrétní typy vozidel.
- Limit pro konkrétní vůz (limit_vuz) – výše limitu pro každou konkrétní předepsanou prohlídku pro konkrétní vozidlo.

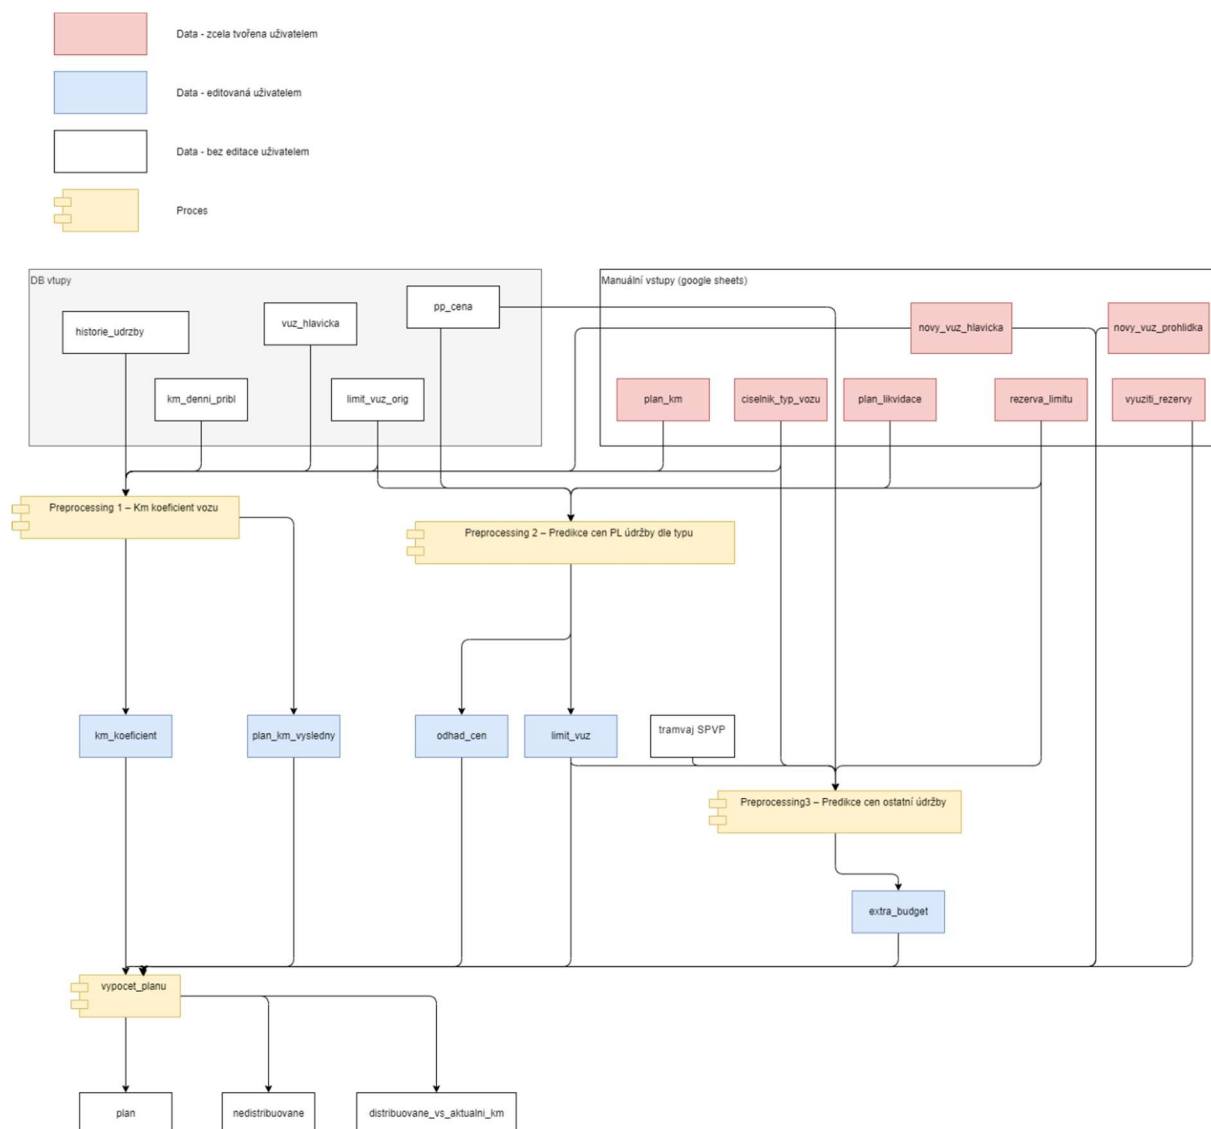
4.3.4 Výsledky prediktivního plánu údržby

V rámci výsledků autor navrhuje i kontrolní mechanismy, které mají sloužit uživateli k validaci celého modelu, ale i k validaci manuálních vstupů a editaci průběžných výsledků. Může například nastat situace, kdy v plánu km budou plánovány km výkony pro depo a typ vozidel, u kterých ale např. uživatel systému naplánuje jejich likvidaci a neprovede náhradu novými vozy. Pro takovou situaci logicky celý model pro dané plánované km nebude schopen najít odpovídající vozidla, kterým by plánované km přiřadil a tudíž se takový výkon neprojeví ani v plánu údržby. Nebo naopak může dojít k „přetížení“ vozidel, která standardně

- Plán údržby (plan) – strukturovaný plán údržby vozidel i s cenami za jejich provedení.
- Nedistribuované km (nedistribuovane) – km výkony, které nebylo možné z různých důvodů přiřadit pro konkrétní vozy a konkrétní dny.
- Srovnání distribuovaných km a aktuálních výkonů (distribuovane_vs_aktualni_km) – srovnání aktuálních výkonů s plánovanými.

4.4 Postup tvorby prediktivního plánu údržby

Celý postup je zobrazen na Obrázek 4. Postup obsahuje tři procesy (preprocessors), které slouží k přípravě mezivýsledků uvedených v kapitole 4.3.3 a algoritmus pro sestavení plánu údržby vozidel. Veškeré výsledky preprocessorů je možné uživatelsky kontrolovat a upravovat.



Obrázek 4 Postup tvorby prediktivního plánu údržby a vyčíslení nákladů (autor)

4.4.1 Preprocessing 1 - km koeficient vozu

Tento preprocessing se reálně sestává z dvou na sebe navazujících procesů. Prvním je výpočet km koeficientu vozu a druhým následná distribuce plánovaných km pro jednotlivé vozy.

Má-li navrhovaný systém být schopen plánovat údržbové zásahy, jejichž realizace je z drtivé většiny vázána na určitý interval kilometrického proběhu (pro každý typ dopravního prostředku je stanoven předepsaný kilometrický proběh vozidla v rozsahu od-do), je nutno predikovat pro každé vozidlo jeho kilometrický proběh, aby bylo možné určit, kdy dané vozidlo dosáhne definované hranice pro realizaci určitého stupně předepsané údržby.

Km koeficient vozu představuje váhové koeficienty dle jednotlivých typů vozidel a následně dle jednotlivých vozidel pro daný typ na základě historických kilometrických proběhů.

Algoritmus 1 Výpočet km koeficientu (autor)

Vstupy: *km_denni_pribl*; *vuz_hlavicka*

Výstupy: *km koeficient*

```

1  foreach vuz_hlavicka/typ_vozu // pro každý typ vozu
2  |   compute sum_typ_vozu = sum km_denni_pribl // spočítej celkové výkony daného typu
   |   vozu
3  |   foreach vuz_hlavicka/ID // pro každý vůz v daném typu
4  |   |   compute sum_vuz = sum km_denni_pribl // spočítej jeho celkový výkon
5  |   |   compute km_koeficient=sum_vuz/sum_typ_vozu //spočítej jeho váhu v daném typu
6  |   end
7  end

```

Pro lepší ilustraci užití tohoto popisu lze uvést následující příklad. Dopravník podnik má pět tramvají typu T3, přičemž váhové koeficienty těchto jednotlivých vozidel budou 10, 15, 20, 20 a 35 % (součet musí dát 100 %). Toto znamená, bude-li např. typu tramvaje T3 přiřazen kilometrický proběh 200 km, pak bude odhadovaný kilometrický proběh jednotlivých tramvají T3 roven 20, 30, 40, 40 a 70 km.

Algoritmus 2 Výpočet plánu kilometrů (autor)

Vstupy: *km_koeficient*; *plan_km*; *plan_likvidace*

Výstupy: *km_plan_vysledny*

```

1  set day = today+1 // nastav den na zítra
2  while day<=max_plan_km/day // pro každý den až do konce existence plánu
3  |   foreach vuz_hlavicka/typ_vozu // pro každý typ vozu
4  |   |   compute sumkm_typ_vozu = plan_km/typ_vozu*váha dne // výkon připadající na
   |   |   daný typ dne, ten se spočítá analogicky Algoritmus 1
5  |   |   compute sum_vaha_typu = km_koeficient/typ_vozu where
   |   |   day<plan_likvidace/den_vyrazeni //celkové váhy všech vozidel daného typu, která
   |   |   nejsou již v likvidaci
6  |   |   foreach vuz_hlavicka/ID // pro každý vůz
7  |   |   |   if day<plan_likvidace/den_vyrazeni // pokud vozidlo nebylo vyřazeno
8  |   |   |   |   compute plan_km/day = km_koeficient/sum_vaha_typu*sumkm_typ_vozu //
   |   |   |   |   km výkon vozidla na daný den

```

```

9      | | | else set plan_km = 0 // pokud je v likvidaci, nemá výkon
10     | | | end
11     | | | end
12     | | | end

```

Rozdíly výkonů mezi pracovními dny a víkendy je zohledněny v kroku 4. Pokud rozdíly jsou známy již z plánů, použijí se rozdíly známé z plánů. Reálně tomu tak ale nebývá.

Jelikož uvedené váhové koeficienty vycházejí z historických dat, může vzniknout problém u nových vozidel, pro která nejsou historická data k dispozici v požadovaném rozsahu. Těmto vozidlům musí být váhové koeficienty přiděleny ručně, přičemž se v praxi předpokládají vyšší hodnoty těchto koeficientů (vychází se z toho, že nová vozidla budou nasazována do provozu přednostně).

Obrázek 5 prezentuje ukázkou vypočtených km koeficientů – viz sloupec B.

	A	B	C	D	E	F	G	H	I	J
	ec_vozu	km_koef	vozovna	vuz_typ	typ_plan	celkem_km	den_km	rok	mesic	vykon_typ_den_adj_plan
307	3729	8,30%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	12725	424	2020	1	5108,004447
308	3705	8,08%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	12383	413	2020	1	5108,004447
309	3711	7,77%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	11901	397	2020	1	5108,004447
310	3708	7,13%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	10919	364	2020	1	5108,004447
311	3730	7,06%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	10812	360	2020	1	5108,004447
312	3709	6,87%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	10520	351	2020	1	5108,004447
313	3712	6,19%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	9488	316	2020	1	5108,004447
314	3713	6,15%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	9426	314	2020	1	5108,004447
315	3707	6,07%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	9306	310	2020	1	5108,004447
316	3710	6,07%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	9295	310	2020	1	5108,004447
317	3702	5,99%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	9172	306	2020	1	5108,004447
318	3714	5,79%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	8877	296	2020	1	5108,004447
319	3703	4,99%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	7648	255	2020	1	5108,004447
320	3706	3,87%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	5931	198	2020	1	5108,004447
321	3704	2,92%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	4476	149	2020	1	5108,004447
322	3701	2,90%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	4448	148	2020	1	5108,004447
323	3728	2,55%	2330	Trolejbus SOLARIS TROLLINO 12 AC	ST 12	3900	130	2020	1	5108,004447
324	3912	1,31%	2330	Trolejbus SOR TNB 12 Standard	ST 12	2015	67	2020	1	5108,004447
641	Součet	100,00%								

Obrázek 5 Ukázkou vypočtených km koeficientů pro trolejbusy Solaris Trollino (autor)

Za účelem validace přístupu distribuce kilometrických proběhů jednotlivým vozidlům na základě odhadnutých váhových koeficientů je třeba provést srovnání skutečných kilometrických proběhů a jejich odhadu – ukázkou tohoto srovnání prezentuje Obrázek 6. Toto srovnání je již v sumárním tvaru (pro jednotlivé typy vozidel, nikoliv pro jednotlivá vozidla) pro kilometrické proběhy, pro která byla k dispozici historická data o skutečně realizovaných dopravních výkonech jednotlivých typů vozidel. Ve sloupci A jsou uvedeny jednotlivé typy

vozidel (jedná se o pracovní dokument, proto jsou uvedeny pracovní názvy), ve sloupci B jsou výkony plánované pro jednotlivé typy vozidel, ve sloupci C jsou uvedeny skutečně realizované dopravní výkony a ve sloupci D je spočítán procentuální podíl mezi plánovaným a skutečným dopravním výkonem. Z obrázku je patrné, že hodnoty podílů se v tomto případě pohybují kolem hodnoty 100 %, proto je možno tento odhad deklarovat za použitelný. U některých typů vozidel se však mohou predikované hodnoty lišit více, než deklaruje Obrázek 6, což bývá způsobeno výlukovou činností, která může tento plán podstatně narušit.

	A	B	C	D	E	F	G	H	I
	typ_plan	vykon_plan	ujete_km_nekomp	plan_vs_ujete					
9	SU 18	20141	22011	92%					
10	SU 10 zaručený	60697	65779	92%					
11	T velkokapacitní	109726	113864	96%					
12	LF	313945	325720	96%					
13	ST 15 zaručený	5543	5720	97%					
14	LF+vlek	3949	4053	97%					
15	T	331147	335740	99%					
16	TRAM - střední kapacita	303094	296388	102%					
17	CNG 12 zaručený	841604	819493	103%					
18	Minibus	31540	30320	104%					
19	26 Tr parciální zaruče	65685	62953	104%					
20	CNG 18	176110	149420	118%					

Obrázek 6 Srovnání skutečných a odhadovaných kilometrických proběhů jednotlivých typů vozidel (autor)

Obrázek 7 potom demonstruje vytvořený plán kilometrických proběhů s detailem na jednotlivá vozidla. Ve sloupci A je uvedeno evidenční číslo daného vozidla, ve sloupci B je uveden stanovený kilometrický koeficient daného vozidla. Ve sloupci F je uveden odhadovaný kilometrický proběh vozidla, ve sloupci G je odhadovaný denní kilometrický proběh. Tento byl stanoven na základě hodnoty celkového denního dopravního výkonu (sloupec J), který je stanoven pro typ vozidla a vozovnu. Denní kilometrický proběh každého vozidla přiřazeného dané vozovně je potom stanoven jako procentuální podíl, který odpovídá hodnotě km koeficientu, z tohoto celkového denního dopravního výkonu. Ve sloupci K je uvedena informace o počtu vozidel daného typu přiřazených dané vozovně. A konečně sloupec L uvádí procentuální podíl mezi plánovaným a skutečným dopravním výkonem souhrnně pro všechna vozidla daného typu.

	A	B	F	G	H	I	J	K	L	M
1	ec_vozu	km_koef	celkem_km	den_km	rok	mesic	vykon_typ_den_adj_plan	pocet_vozu_typ	plan_vs_ujete_typ	
29	1041	4,19%	4163	139	2020	1	3312,417969	38	99%	
30	1045	4,19%	4163	139	2020	1	3312,417969	38	99%	
31	987	4,17%	4142	138	2020	1	3312,417969	38	99%	
32	965	4,16%	4134	138	2020	1	3312,417969	38	99%	
33	1042	3,99%	3962	132	2020	1	3312,417969	38	99%	
34	902	3,92%	3893	130	2020	1	3312,417969	38	99%	
35	1046	3,91%	3882	129	2020	1	3312,417969	38	99%	
36	1007	3,90%	3874	129	2020	1	3312,417969	38	99%	
37	914	3,83%	3809	127	2020	1	3312,417969	38	99%	
38	990	3,80%	3777	126	2020	1	3312,417969	38	99%	
39	986	3,78%	3759	125	2020	1	3312,417969	38	99%	
40	1003	3,64%	3622	121	2020	1	3312,417969	38	99%	
41	992	3,64%	3615	120	2020	1	3312,417969	38	99%	
42	988	3,47%	3453	115	2020	1	3312,417969	38	99%	
43	1017	3,42%	3396	113	2020	1	3312,417969	38	99%	
44	1004	3,40%	3378	113	2020	1	3312,417969	38	99%	

Obrázek 7 Plán kilometrických proběhů v detailu na jednotlivá vozidla (autor)

4.4.2 Preprocessing 2 – Predikce cen plánované údržby dle typu

Další preprocessing řeší otázku odhadu nákladů plánovaných údržbových zásahů v závislosti na typu preventivního údržbového zásahu a typu vozidla. K predikci cen plánované údržby lze využít různé metody, jako Poissonův proces a modely časových řad. Jelikož vstupní data zpravidla obsahují anomálie a není možné je zcela vyčistit, tak autor doporučuje využití časových řad s integrovaným klouzavým průměrem, který „vyhladí“ případné anomálie, které by nebyl schopen postihnout např. Poissonův proces.

Algoritmus 3 Výpočet ceny plánované údržby (autor)

Vstupy: historie_udrzby; pp_cena

Výstupy: odhad_cen

```

1 foreach vuz_hlavicka/typ_vozu // pro každý typ vozu
2   | foreach historie_udrzby/typ_udrzby // pro každý typ údržby
3   |   | compute ARIMA (Kinney, 1978) // spočtení časové řady cen
4   |   | end
5   | end

```

V případě neexistence historických dat o daném typu údržby není možno predikci provést a pak je uživateli umožněno tyto očekávané náklady zadat ručně.

Ukázku odhadnutých nákladů na jednotlivé preventivní údržbové zásahy prezentuje Obrázek 8.

	A	B	C	D	E	F	G	H
1	prikaz_pu_nazev	vuz_typ	ciselnik_pp	trakce	odhad_ceny	odhad_ceny_rucne	odhad_ceny_rucne_drive	tram_podil
3	Střední prohlídka SP	Tramvaj - všečný vůz VV60LJ 08		Tramvaj	308410			0,7072684352
6	Střední prohlídka SP	Tramvaj T3 Zrychlovač	08	Tramvaj	488945			0,4886950026
9	Střední prohlídka SP	Tramvaj T3 R.P. Progress	08	Tramvaj	493984			0,4278495661
12	Střední prohlídka SP	Tramvaj T3 R.E. Europulss	08	Tramvaj	394270			0,7807733279
15	Střední prohlídka SP	Tramvaj T3 G TV8	08	Tramvaj	440548			0,4736117109
18	Střední prohlídka SP	Tramvaj T6A5 TV3	08	Tramvaj	525004			0,5757345717
20	Střední prohlídka SP	Tramvaj ŠKODA LTM 10 08 08		Tramvaj	569156			0,5575431479
22	Velká prohlídka VP	Tramvaj ŠKODA LTM 10 08 10		Tramvaj				
25	Střední prohlídka SP	Tramvaj Inekon TRIO Elin	08	Tramvaj	566709			0,6563267921
26	Velká prohlídka VP	Tramvaj Inekon TRIO Elin	10	Tramvaj	2790216			0,8117209689
29	Střední prohlídka SP	Tramvaj Inekon TRIO Europ	08	Tramvaj	729616,28			0
30	Velká prohlídka VP	Tramvaj Inekon TRIO Europ	10	Tramvaj	2790216			0,608089453
35	Střední prohlídka SP	Tramvaj VarioLFR.E Europu	08	Tramvaj	495443			0,387243387
36	Velká prohlídka VP	Tramvaj VarioLFR.E Europu	10	Tramvaj	1430009			0,5407940188
40	Střední prohlídka SP	Tramvaj VarioLFR.S Škoda	08	Tramvaj	476388			0,3139741488
41	Velká prohlídka VP	Tramvaj VarioLFR.S Škoda	10	Tramvaj		1400000	1400000	
44	Střední prohlídka SP	Tramvaj VarioLF2 Europulss	08	Tramvaj		570000	570000	
45	Velká prohlídka VP	Tramvaj VarioLF2 Europulss	10	Tramvaj	2011835			0,6380819004
48	Střední prohlídka SP	Tramvaj VarioLF2R.S Škoda	08	Tramvaj	555133			0,4796014108

Obrázek 8 Odhadnuté ceny jednotlivých typů údržby (autor)

4.4.3 Preprocessing 3 – Predikce cen ostatní údržby

Kromě plánovaných údržbových úkonů v průběhu provozu dochází i k dalším nákladům na údržbu, které plynou z údržbových zásahů, jež je obtížné predikovat. V tomto případě se jedná zejména o následující situace:

- V průběhu preventivního údržbového zásahu odhaleny závady na vozidle, které je nutno odstranit.
- Údržba po poruše.
- Údržba po nehodě.

V prvním případě jsou úkony techniků na sebe v čase vázány, což představuje významný praktický problém, který významně komplikuje teoretické, resp. idealistické možnosti přístupu řešení daného problému. Spotřeba materiálu, tedy i ceny údržby, jsou ovlivněny jejich zadáváním pro jiné prohlídky a údržbu. Např. spotřebovaný materiál, a tedy i cena prohlídky/opravy, zahrne jen do jedné události a druhá událost je bez spotřebovaného materiálu a tedy i ceny nebo není vůbec v datech evidována. Jedná se o přirozený problém. Technik nemá motivaci „štěpit“ svou práci, kterou vnímá jako celistvou do více záznamů v evidenci a tím si přiděluje v dané situaci zbytečnou administrativní práci.

Pro vyřešení výše uvedeného problému lze užít obdobný postup, jako u predikce nákladů. V kapitole 4.4.2 byl stručně popsán postup predikce nákladů preventivních údržbových zásahů, tyto náklady odpovídají standardnímu rozsahu. K těmto nákladům je nutno připočítat náklady na neplánované vícepráce, které jsou stanoveny jako procentuální část ze standardních (plánovaných) nákladů.

Algoritmus 4 Výpočet ceny neplánované údržby (autor)

Vstupy: *historice_uzrzby; pp_cena; odhad_cen*

Výstupy: *extra_budget/neplanovana_uzrzba*

```

1  foreach vuz_hlavicka/typ_vozu // pro každý typ vozu
2      set sum_PL=0
3      set sum_NP=0
4      foreach historie_uzrzby/typ_uzrzby // pro každý typ údržby
5          if historie_uzrzby/typ_uzrzby ∈ PL // pro plánovanou údržbu
6              foreach histoire_uzrzby/ID // pro každou údržbu
7                  compute sum_PL=sum_PL+pp_cena/ID // načítání sumy plánované údržby
8              end
9          else // pro neplánovanou údržbu
10             foreach histoire_uzrzby/ID // pro každou údržbu
11                 compute sum_NP=sum_NP+pp_cena/ID // načítání sumy plánované údržby
12             end
13         end
14     end
15     Compute extra_budget/neplanovana_uzrzba = sum_NP/sum_PL*odhad_cen //
        poměrný výpočet ceny neplánované údržby
16 end

```

Každý typ údržby je datově přímo vázán i na typ vozidla. Tyto procentuální poměry se snadno spočítají z historických dat viz. ukázka na Obrázek 9 a pro další výpočet se použije jen jejich průměr. Sloupec C obsahuje náklady plánované údržby, sloupec D náklady neplánované údržby, sloupec E je podíl nákladů neplánované údržby vůči údržbě plánované a F je obsahuje podíl nákladů neplánované údržby vůči plánované pro jednotlivé trakce. Do uvedeného případu byl použit jen pro vizualizaci rozpad na jednotlivé roky.

	A	B	C	D	E	F	G	H	I	J
1	rok	trakce	PL	NP	podil	podil_prumerny				
2	2017	Autobus	15 446 736 Kč	12 038 569 Kč	78%	73%				
3	2018	Autobus	17 386 152 Kč	12 765 225 Kč	73%	73%				
4	2019	Autobus	17 646 399 Kč	11 711 561 Kč	66%	73%				
5	2017	Tramvaj	68 302 599 Kč	25 547 575 Kč	37%	43%				
6	2018	Tramvaj	70 437 526 Kč	32 316 269 Kč	46%	43%				
7	2019	Tramvaj	54 074 196 Kč	23 941 231 Kč	44%	43%				
8	2017	Trolejbus	4 413 801 Kč	8 251 823 Kč	187%	219%				
9	2018	Trolejbus	4 917 927 Kč	9 770 945 Kč	199%	219%				
10	2019	Trolejbus	3 076 675 Kč	8 381 239 Kč	272%	219%				

Obrázek 9 Ukázka procentuálního podílu nákladů neplánované údržby vůči nákladům plánované údržby (autor)

Co se týče nákladů na údržbu po poruše, resp. nehodě, na základě historických dat lze analogicky odhadnout sumární náklady na tento typ údržby pro jednotlivé kategorie provozovaných vozidel (tramvaje, autobusy, trolejbusy) – ukázka viz Obrázek 10. O tuto průměrnou částku je potom snížen plánovaný rozpočet na údržbu, se kterým se pracuje při plánování preventivní údržby.

	A	B	C	D	E	F	G	H	I	J
1	rok	trakce	predvidatelnost	castka	prumerna_castka					
2	2017	Autobus	NE	4 105 154 Kč	5 035 069 Kč					
3	2018	Autobus	NE	5 269 363 Kč	5 035 069 Kč					
4	2019	Autobus	NE	5 730 689 Kč	5 035 069 Kč					
5	2017	Autobus	NP	30 124 115 Kč	33 083 290 Kč					
6	2018	Autobus	NP	33 271 820 Kč	33 083 290 Kč					
7	2019	Autobus	NP	35 853 935 Kč	33 083 290 Kč					
8	2017	Tramvaj	NE	7 632 725 Kč	4 639 862 Kč					
9	2018	Tramvaj	NE	1 121 393 Kč	4 639 862 Kč					
10	2019	Tramvaj	NE	5 165 468 Kč	4 639 862 Kč					
11	2017	Tramvaj	NP	16 751 249 Kč	13 996 101 Kč					

Obrázek 10 Vypočítané roční náklady na údržbu po poruše, resp. nehodě (autor)

Kromě odhadu nákladů na realizaci preventivního údržbového zásahu Preprocessing 3 rovněž predikuje doby trvání jednotlivých typů údržbových zásahů. V případě odhadu doby trvání se postupuje analogicky, jako u odhadu nákladů. Ze záznamů historie údržby se použije jen průměrné trvání jednotlivých typů prohlídek – ukázka viz. Obrázek 11.

	A	B	C	D	E	F
	pp_nazev	vuz_typ	ciselnik_pp	trakce	pocet_zaznamu	pocet_dnu
2	preventivní prohlídka c	Tramvaj - vlečný vůz VV60LF Bez trakční výzbroje	08	Tramvaj	2	262,2916667
3	preventivní prohlídka c	Tramvaj Inekon TRIO Elin	08	Tramvaj	1	64
4	preventivní prohlídka c	Tramvaj Inekon TRIO Europulse	08	Tramvaj	1	80
5	preventivní prohlídka c	Tramvaj KT8D5.RN1. TV3	08	Tramvaj	8	87,81770833
6	preventivní prohlídka c	Tramvaj ŠKODA LTM 10.08 Elin	08	Tramvaj	3	89,97222222
7	preventivní prohlídka c	Tramvaj T3 G TV8	08	Tramvaj	3	49,375
8	preventivní prohlídka c	Tramvaj T3 R.E. Europulse	08	Tramvaj	1	54,91666667
9	preventivní prohlídka c	Tramvaj T3 R.P. Progress	08	Tramvaj	33	46,7209596
10	preventivní prohlídka c	Tramvaj T3 Zrychlovač	08	Tramvaj	6	47,28472222
11	preventivní prohlídka c	Tramvaj T6A5 TV3	08	Tramvaj	25	50,36833333
12	preventivní prohlídka c	Tramvaj VarioLF3/2 Europulse	08	Tramvaj	1	78,70833333
13	preventivní prohlídka c	Tramvaj VarioLF 5 Europulse	08	Tramvaj	10	72,72222222

Obrázek 11 Ukázka odhadu doby trvání preventivních údržbových zásahů (autor)

4.5 Výpočet prediktivního plánu údržby


K výpočtu, resp. vytvoření samotného plánu údržby lze přistoupit mnoha přístupy. Jelikož se v této práci navrhuje postup, který má umožnit navržení plánu údržby s opomíjenými podmínkami, ale zároveň i navrhnout, jak by měly být tyto opomíjené podmínky zahrnuty, tak je vhodné zvolit formalismus pro maximalistické řešení, tedy takové, které bude vhodné i pro zakomponování v této práci pomíjených podmínek.

4.5.1 Grafová interpretace

Problém údržby má síťové rysy stejně jako problémy PNS (process-network synthesis), které se řeší pomocí metodiky P-Grafu (Adonyi, Heckl, & Olti, 2013).

Obrázek 12 znázorňuje nejobecnější obecný graf PNS, který se využívá pro základní výrobní systémy. Tyto systémy mohou být spojitě, dávkové nebo smíšené. Při spojitém provozu se výstup jednotky realizuje nepřetržitě od započetí činnosti. V dávkovém provozu jsou vstupy přiváděny do jednotky v jeden moment, následně jsou zpracovány a všechny výstupy jsou zpracovány také v jeden moment. Následně se cyklus opakuje. Spojitá jednotka může provádět

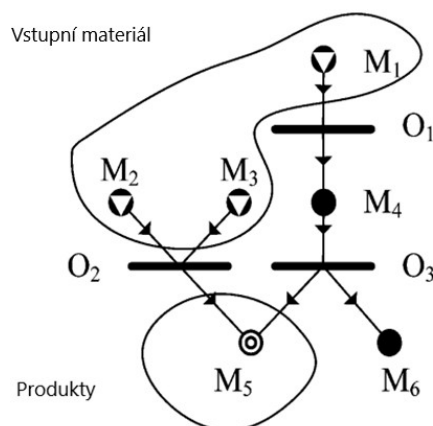
pouze jednu operaci, ale dávková jednotka může realizovat různé úlohy. Výhodou dávkových systémů je, že jsou velmi flexibilní, a proto je relativně snadné měnit konečné výrobky nebo výrobní metody. Naproti tomu spojité systémy jsou z dlouhodobého hlediska méně nákladné na provoz. Problematika PNS se zabývá primárně spojitými systémy. Elementární krok pak realizuje transformaci vstupních surovin na výrobky, resp. výstupní materiál.



Obrázek 12 Graf reprezentující jednotky údržby (Adonyi, Heckl, & Olti, 2013)

Sestavení grafu je tedy úkolem reprezentující sestavení elementárních kroků do takové sítě, která je optimální podle určitých kritérií, jako jsou náklady, zisk apod. Určením nejvýhodnější, tj. optimální sítě lze zvýšit efektivitu a snížit náklady. Obrázek 12 obsahuje jednu výrobní jednotku O_1 , se dvěma vstupními materiály M_1 - M_2 a třemi výstupními materiály resp. produkty M_3 - M_5 .

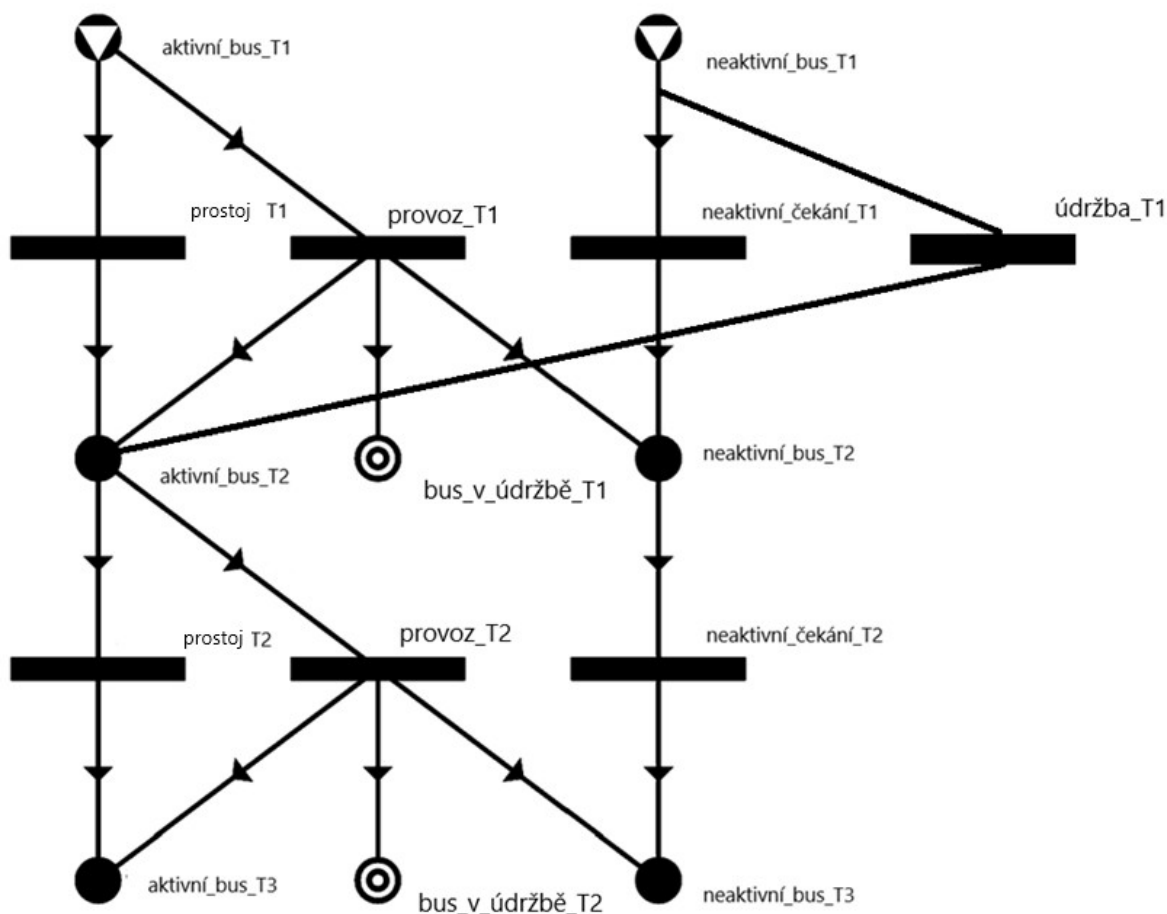
Obrázek 13 zobrazuje už složitější síť se třemi provozními jednotkami O_1 - O_3 a vstupními materiály M_1 - M_3 , jeden mezivýrobek M_4 , jeden produkt M_6 a jeden vedlejší produkt M_5 .



Obrázek 13 PNS síť zahrnující tři provozní jednotky a šest materiálů (Adonyi, Heckl, & Olti, 2013)

Aby bylo možné použít P-grafy pro optimalizaci problému údržby vozidel, je třeba identifikovat vazby mezi úkony údržby a provozními jednotkami. Tyto vazby jsou znázorněny na Obrázek 14. Prvky grafu v kategorizaci PNS:

- Vstupní materiál:
 - aktivní_bus_TX - vozidlo, které je dostupné/provozoschopné.
 - neaktivní_bus_TX – vozidlo, které není dostupné/provozoschopné.
 - bus_v_údržbě_TX – vozidlo, které je v údržbě.
- Operační jednotky:
 - prostoj_TX – čekání provozuschopných vozidel na další provoz.
 - provoz_TX – vozidlo je v provozu.
 - neaktivní_čekání_TX – čekání ne provozuschopných vozidel.
 - údržba_TX – realizace údržby neprovozoschopných vozidel.
- Vedlejší produkty:
 - bus_v_údržbě – stav údržby, kam je možné se dostat proaktivně bez čekání na neprovozoschopný stav. Vztahuje se na plánovanou údržbu.



Obrázek 14 P-graph realizace údržby vozidel (autor)

Sestavený graf v řádcích reprezentuje provozní dny se strukturovanými aktivitami, které jsou reprezentovány jako operační jednotky. Vozy se v čase pohybují mezi jednotlivými aktivitami a stavy. Graf nemá ve svém výchozím stavu ohodnocené hrany, resp. lze uvažovat na všech hranách jen s hodnotou 1.

4.5.2 Generování grafu

Samotný P-graf je algoritmický již při generování strukturálního modelu a je schopen poskytnout již při své konstrukci řešení, které nemusí dodržovat všechny podmínky, ale poskytuje alespoň nějaké řešení. Vzhledem k opomíjeným podmínkám v této práci již vygenerovaný graf představuje samotné řešení úlohy.

Pro tvorbu grafu platí následující pravidla:

- Každý vůz je v jeden den jen v aktivitě (provozu) nebo v údržbě

- Vozy vstupují do údržby až ve chvíli, kdy se stanou neprovozuschopné. Neprovozuschopné se vozidlo stává v následujících situacích:
 - Vozidlo překročilo maximální povolenou hodnotu limitu předepsané prohlídky, volitelně včetně tolerance.
 - Vozidlu vznikl požadavek na údržbu po nehodě nebo jiné události.

Graf se vždy generuje ode dne následujícího po dni, ze kterého jsou známé skutečné výkony. Na vstupu je známo, jaká vozidla pro daný den budou v údržbě (rozhodnutí z minulého dne) a jaké budou v provozu. Následující Algoritmus 5 se tedy spouští vždy po uzavření provozního dne a vždy po spuštění Algoritmus 2. Graf se generuje „po sloupcích“, tedy po vozidlech.

Algoritmus 5 Postup tvorby P-grafu pro údržbu vozidel (autor)

Vstupy: *historie_uzrby; km_denni_pribl; plan_km_vysledny; limit_vuz; rezerva_limitu; vyuziti_rezervy; vuz_hlavicka*

Výstupy: *plán údržby*

```

1  foreach vuz_hlavicka/ID // pro každé vozidlo
2      set day = today+1 // nastav den na zítra
3      set plan_km_real/(day-1) = km_denni_pribl/day //nastav reálný výkon vozu pro
      dnešní den z historie
4      while day<=max plan_km/day // do konce existence plánu
5          if provoz/day // je vozidlo v daný den v provozu?
6              compute plan_km_real/day = plan_km_real/(day-1)+plan_km/day // připočti
              plánované výkony pro daný den
7              set P=1 // nastav prohlídku na nejvyšší stupeň
8              while P<=max P // až do nejnižší prohlídky
9                  if vyuziti_rezervy = 1 // používá se rezerva?
10                     if plan_km_real-historie_uzrby/km > limit_vuz*(1+rezerva_limitu)
                        //došlo k dosažení limitu prohlídky s rezervou?
11                         | Algoritmus 6 // podalgoritmus nastavení prohlídek
12                     else // pokračuje se až do dalšího dne
13                 elseif plan_km_real-historie_uzrby/km > limit_vuz // došlo k dosažení
                        limitu prohlídky bez rezervy?
14                     | Algoritmus 6 // podalgoritmus nastavení prohlídek
15                 else // pokračuje se až do dalšího dne
16                 end

```

```

17   |   | else set provoz/(day+1) = 1 // nastav na další den vozidlo do provozu
18   |   | end
19 end

```

Algoritmus 6 Algoritmus nastavení prohlídek (autor)

Vstupy: parametr P

Výstupy: provedení záznamů o provedených prohlídkách

```

1 set provoz/(day+1)=0 // nastav na zítra prohlídku
2 set PP=P // od aktuální prohlídky
3 while PP<=max P // až po nejnižší prohlídku
4   | compute historie_udrzby/km=plan_km_real //pro každý typ nižší prohlídky proved'
   | záznam o provedení prohlídky
5 end

```

Algoritmus 6 slouží jen pro úsporu prostoru a zjednodušení zápisu. Jedná se reálně o samostatnou funkci.

Navržený Algoritmus 5 nezohledňuje pravděpodobnost výskytu neplánované údržby. Její cena se počítá nezávisle v Algoritmus 4. Pokud by se stochasticky uvažovalo o výskytu neplánované údržby, tak by celý plán údržby byl sám o sobě velmi nestabilní, protože samotný plán údržby je čistě deterministický. V P-grafu je totiž reprezentován vedlejším produktem, který reprezentuje samotnou údržbu. Tento produkt má na časové ose zcela deterministický charakter. Výskyt jakékoli události v jakémkoli harmonogramu na základě jakéhokoli stochastického přístupu je postup, který se v deterministických plánech nikdy neaplikuje a patří spíše do simulačních modelů.

Generování grafu popsané v Algoritmus 5 je reálně degenerací stochastického P-grafu, protože v něm chybí rozhodovací úloha vyplývající z kapacitních omezení. Výhodou je rychlost a zcela deterministické chování celého navrženého systému. Výsledky navrženého procesu by se v praxi měly přepočítávat každý den po uzavření provozního dne.

4.5.3 Opomíjené podmínky

Pokud by se přestala používat zjednodušení v podobě opomíjených podmínek podobě kapacit techniků, údržbářských čt a kapacit ploch pro realizaci údržby, tak by graf měl ohodnocené hrany (ohodnocení hran by reprezentovalo čas) a přibyl by navíc další vstupní

materiál, který by reprezentoval techniky, údržbářské čety a kapacity ploch pro realizaci údržby. Postup tvorby takového grafu je popsán v (Adonyi, Heckl, & Olti, 2013).

Model P-grafu je schopen využít strukturální vlastnosti problému a v důsledku toho zmenšit prostor pro vyhledávání. Obecný algoritmus B&B (branch and bound) obvykle rozhoduje o jedné rozhodovací proměnné v čísle v jednom kroku, avšak algoritmus ABB (accelerated branch and bound), který lze využít v P-grafech, je schopen rozhodnout o více celočíselných hodnotách najednou.

Konkrétní postup, jak se řeší rozhodovací úlohy PNS pomocí ABB je popsán v (Friedler, Varga, & Fan, 1995).

4.6 Shrnutí navrhovaného postupu

Obecný postup tvorby plánů údržby vozidel a určení nákladů na údržbu jsou navrženy takovým způsobem, aby bylo dosaženo zrychlení a zpřesnění těchto procesů. V rámci navrženého postupu a algoritmů je částečně zachováno metod znalostních – formou manažerských vstupů do editace mezivýsledků a možností ovlivnění chování jednotlivých algoritmů pomocí dodatečných, resp. nově navržených datových zdrojů. Navržený postup významně využívá kombinací metod založených na zpracování dat a tradičních algoritmů v podobě tvorby síťového grafu PNS.

S ohledem na využitelnost navrženého postupu a algoritmů v praxi pro československé prostředí jsou navrženy i kroky spočívající v zakomponování proměnných, které v této disertační práci byly opomenuty. Jejich výčet i místo vhodného zakomponování jsou v této práci jasně uvedeny formou rozšíření PNS úlohy na P-graf.

Navržený postup a algoritmy jsou navrženy tak, aby neovlivnili stávající procesy přípravy dat a způsob jejich evidence ze strany uživatelů - dopravních podniků.

Navržený postup využívá algoritmy, které jsou všechny implementované v dostupných knihovněch v jazycích R a Python a celý navržený systém tak může na jakémkoli dopravním podniku replikovat každý jen se základní znalostí programování a matematiky.

Na základě praktických zkušeností autora této disertační práce by se reálný čas potřebný pro výpočet všech algoritmů, resp. kompletního výpočtu prediktivního plánu údržby, měl pohybovat maximálně v řádu minut. Praktickým problémem užití navrhovaného postupu

a algoritmů zůstává čištění dat a načítání a ukládání výsledků z/do datových úložišť. Řešení tohoto praktického problému, který je reálně jen problém implementace na straně IT oddělení dopravního podniku, může negativně ovlivnit čas celého výpočetního procesu. V rámci případové studie bude následně ověřen i praktický dopad výše uvedených praktických problémů.

Hlavní motivace vzniku této disertační práce, tedy vytvoření postupu a algoritmů, které by sloužili jako podpora manažerského rozhodování při plánování údržby vozidel a usnadnění kalkulace nákladů na údržbu plánovanou i neplánovanou, jsou tedy naplněny.

Výstup prediktivního plánu údržby, resp. Algoritmus 5 je i seznam realizovaných prohlídek, které jsou na Obrázek 14 zobrazeny formálně jako vedlejší produkty PNS grafu. Tento vedlejší produkt je sám o sobě vstupem pro funkční plán skladových zásob zabezpečující z pohledu dopravce optimální spolehlivost údržby vozidel. Tím je splněn i poslední dílčí cíl této disertační práce.

Na základě důkladného literárního přehledu lze konstatovat, že navrhovaný postup a algoritmy jsou ve své kombinaci nové a originální. V dohledané literatuře není popsán žádný postup a algoritmy pro v této disertační práci požadované omezující podmínky a požadavky na říditelnost ze stran uživatelů systému.

5 PŘÍPADOVÁ STUDIE

Celý postup navržený v kapitole 4 včetně algoritmů byl plně implementován autorem této práce na datech poskytnutých Dopravním podnikem Ostravy a.s. v rámci projektu TAČR CK01000060. Zdrojové kódy v jazyce R vznikly za přispění Kateřiny Šulcové Ph.D.

Celý postup a algoritmy byly validovány a verifikovány ve spolupráci se zaměstnanci managementu odpovědnými za tvorbu plánů údržby vozidel.

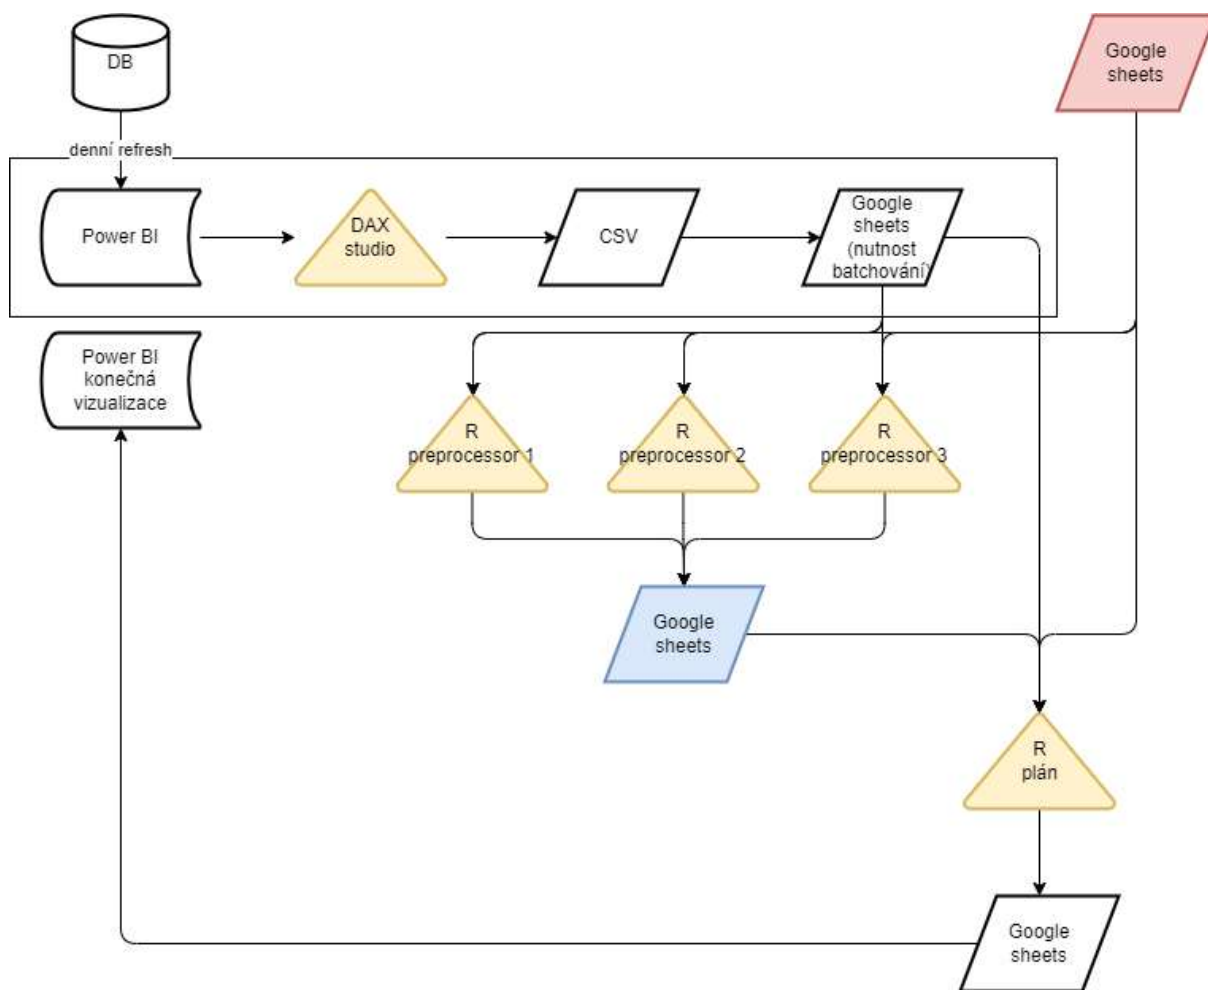
Celý navržený postup, jeho výstupy a přínosy, byly prezentovány na společném zasedání Dopravně provozních skupin Sdružení dopravních podniků České a Slovenské republiky.

V dalších kapitolách jsou uvedeny zejména odchylky od navrženého postupu v kapitole 4, které bylo v praxi nutné učinit, aby v daném případě bylo dosaženo efektivního využití navrženého postupu. Uvedené odchylky by měly sloužit čtenářům této disertační práce jako návod pro reálnou implementaci v praxi i v jiných případech.

5.1 Zpracování databázových dat

Pro validaci a verifikaci nebylo možné mít k dispozici přímý přístup do provozních databází a bylo třeba postavit celý systém tak, aby jakkoli nezatěžoval žádný provozní systém. I v případě implementace daného postupu na jiném dopravním podniku musí být nejprve systém zbudován v prostředí „sandboxu“, aby jeho běh nikterak neohrožoval provozní systémy dopravního podniku, a přitom mohl být účinně validován a verifikován.

V daném případě a v daném čase byl zvolen na dopravním podniku pro jiné účely již existující způsob vyčítání databázových dat pomocí nástroje Power BI od společnosti Microsoft. Celý proces je zobrazen na Obrázek 15. V rámci jednotlivých datových sad a procesů je komprimován do zjednodušujícího schématu celému postupu na Obrázek 4.



Obrázek 15 Proces nepřímého vyčítání a zpracování dat (autor)

Data načtená do nástroje Power BI byla v denní frekvenci exportována pomocí nástroje DAX studio, ve kterém se zároveň řešila i část čištění dat a následně v dávkách nahrávána k dalšímu zpracování.

Pro zkušenosti uživatelů systému s tabulkovým procesorem MS Excel byly pro veškeré manuální vstupy a průběžné kontroly výsledků využity Google sheets. Ty byly upřednostněny před sdílenými sešity MS Excel z důvodu snazšího řešení autentizace přímo z kódu R.

R kódy byly spouštěny v modulu Machine learning studio MS SQL Serveru 2020 s následujícími moduly:

- Dplyr,
- lubridate,
- forecast,

- stringi,
- stringr,
- reshape2,
- data.table,
- tidyr,
- googledrive,
- googlesheets4.

Výsledné plány údržby pak byly opět načítány do Power BI, kde jim byla vytvořena uživatelsky přívětivá prezentace s možností filtrování podle trakce, typů vozidel apod. Výsledná prezentace je znázorněna na Obrázek 16.

Plán budgetu				
trakce	NE	NP	PL	Celkem
Autobus	2 483 364,50	20 112 515,46	4 793 211,97	27 389 091,93
Tramvaj	2 313 188,22	20 539 616,93	34 293 452,58	57 146 257,73
Trolejbus	336 115,27	7 778 942,71	1 254 492,01	9 369 550,00
Celkem	5 132 667,99	48 431 075,11	40 341 156,56	93 904 899,66

Měsíční plán PL prohlídek dle trakce a typu prohlídky														
Rok-Mesíc-uct	2020-10	2020-11		2020-12		2021-01		2021-02		2021-03		2021-04		2021-05
trakce	odhad_ceny	# prohlídek	odhad_ceny	# prohlídek	odhad_ceny	# prohlídek	odhad_ceny	# prohlídek	odhad_ceny	# prohlídek	odhad_ceny	# prohlídek	odhad_ceny	# prohlídek
Autobus	1 087 197,34	503	738 969,25	321	588 595,70	264	724 270,63	266	700 700,75	238	683 193,41	326	740 740,74	326
Tramvaj	562 270,13	146	1 794 094,85	134	5 127 800,46	129	2 894 080,98	125	1 785 057,09	114	3 339 911,96	140	7 407 767,00	7 4 7
Trolejbus	125 809,97	17	132 379,48	18	122 775,20	33	143 818,75	12	196 072,58	18	394 632,51	105	1 050 000,00	105
Celkem	1 775 277,44	666	2 665 443,58	473	5 839 171,36	426	3 762 170,36	403	2 681 830,41	370	4 417 737,87	571	7 407 767,00	7 4 7

Plán SP a VP tramvajů dle data zúčtování										
cisekik_pp	2020-11	2020-12	2021-01	2021-02	2021-03	2021-04	2021-05	2021-06	2021-07	Celkem
08	2 038 361,97	2 847 594,11	1 549 265,55	1 962 458,23	2 181 798,49	2 766 251,95	5 228 577,60	1 333 027,13		19 907 335,03
10	4 406 698,63	2 203 349,31		2 208 349,31	7 000 000,00	1 750 000,00	1 750 000,00	5 703 349,31		25 016 746,57
Celkem	2 038 361,97	7 254 292,74	3 752 614,86	1 962 458,23	4 385 147,80	9 766 251,95	6 978 577,60	3 083 027,13	5 703 349,31	44 924 081,60

Detail prohlídky												
datum_prohlidky	datum_zuctovani	cisekik_pp	ec_vozu	prikaz_pu_nazev	odhad_ceny	tramNPodhad_ceny	dosazena_hodnota	limit	limit_rez	den_km	trakce	vuz_byp
21. 8. 2020	20. 12. 2020	10	1328	Velká prohlídka VP	1 430 009,00	773 340,31	0,00	480000	510000	Ujeté kilometry	Tramvaj	Tramvaj VarioLFR
1. 9. 2020	31. 12. 2020	10	1330	Velká prohlídka VP	1 430 009,00	773 340,31	92,60	480000	510000	Ujeté kilometry	Tramvaj	Tramvaj VarioLFR
3. 9. 2020	27. 11. 2020	08	1513	Střední prohlídka SP	824 838,00	508 189,13	15,60	120000	130000	Ujeté kilometry	Tramvaj	Tramvaj KT8D5.R
9. 9. 2020	26. 11. 2020	08	983	Střední prohlídka SP	493 984,00	211 350,84	2,00	100000	110000	Ujeté kilometry	Tramvaj	Tramvaj T3 R.P. P
15. 9. 2020	1. 12. 2020	08	1322	Střední prohlídka SP	495 443,00	191 857,03	0,00	480000	490000	Ujeté kilometry	Tramvaj	Tramvaj VarioLFR
22. 9. 2020	11. 12. 2020	08	1124	Střední prohlídka SP	525 004,00	302 262,95	3,00	120000	130000	Ujeté kilometry	Tramvaj	Tramvaj T6A5.TV
1. 10. 2020	1. 10. 2020	02	1702	pu b prohlídka / kp bp z /	3 331,78		11 135,94	10000	11000	Ujeté kilometry	Tramvaj	Tramvaj Stadler T
1. 10. 2020	1. 10. 2020	02	1707	pu b prohlídka / kp bp z /	3 331,78		11 025,57	10000	11000	Ujeté kilometry	Tramvaj	Tramvaj Stadler T

Obrázek 16 Prezentace plánu údržby v Power BI (autor)


Časová náročnost jednotlivých procesů z Obrázek 15 je uvedena v tabulce Tabulka 3.

Proces	Časová náročnost
Převod DB -> Power BI -> Google sheets	~3 hod
Načtení dat preprocessing 1 – Km koeficient vozu	~15 min

Proces	Časová náročnost
Preprocessing 1 – Km koeficient vozu	<1 min
Uložení dat preprocessingu 1 – Km koeficient vozu	<1 min
Načtení dat preprocessing 2 – Predikce cen PL údržby dle typu	~15 min
Preprocessing 2 – Predikce cen PL údržby dle typu	~3 min
Uložení dat preprocessingu 2 – Predikce cen PL údržby dle typu	<1 min
Načtení dat preprocessing 3 – Predikce cen ostatní údržby	~2 min
Preprocessing 3 – Predikce cen ostatní údržby	~2 min
Uložení dat preprocessingu 3 – Predikce cen ostatní údržby	<1 min
Načtení dat plánu údržby do Power BI	~2 min

Tabulka 3 Časová náročnost nepřímého načítání a zpracování dat (autor)

Z časů uvedených v Tabulka 3. tabulky je zřejmé, že časové úzké hrdlo celého procesu nepřímého zpracování dat je v načítání dat z databáze a jejich převodu do Google sheets a následně i načítání preprocessingů z Google sheets. V čistém architektonickém řešení by R skripty měly mít přímý přístup do databáze, nad kterou by výpočty prováděly „online“. V praxi není nezbytné, aby R skripty byly připojeny na provozní databáze, ale mohou se připojovat na zrcadlená data např., v datovém skladu. Tato architektura je zobrazena na Obrázek 17. V uvedené architektuře by měla být odstraněna úzká hrdla resp. dlouhé časy na načítání a ukládání dat uvedené v Tabulka 3.



Obrázek 17 Proces provozního načítání a zpracování dat (autor)

5.2 Čištění dat

Čištění dat představuje samo o sobě proces, která je z podstaty věci unikátní pro každý případ užití. V každém dopravním podniku bude vždy jinak stará a kvalitní datová základna o historii najetých km, prováděné údržbě a nákladů, která s údržbou byla spojena.

V daném případě jsou uvedeny situace, které bylo nutné řešit, protože i způsob řešení uvedených problémů vždy závisí na jejich charakteru a četnosti. Zkušenosti autora této disertační práce říkají, že čištění dat u budování systémů jako je ten navržený v této práci, zabere zhruba 1/3 veškerého času na implementaci celého systému:

- Duplicitní záznamy.
- Problémy s malými a velkými písmeny pro párování dat.
- Filtrace nerelevantních dat.

- Veškeré numerické hodnoty v historii najetých km a cenách obsahují anomálie kvůli špatnému zápisu desetinné čárky.
- Datумы událostí (např. 1.1.1900) představují v interním užití na každém dopravním podniku nějaký význam.
- Některý spotřebovaný materiál se doplňuje zcela náhodně a ne vždy podle předepsaného rozsahu v rámci plánovaných prohlídek (např. koště, kýbl a hadr).
- Některý spotřebovávaný materiál se v čase kvantitativně mění. Např. dopravní podnik v čase vymění dodavatele oleje a na místo lahví oleje o objemu 1l používá lahve oleje o objemu 2l. Balení o větším objemu pak technikovi na spotřebu vydrží déle, tedy pro některé prohlídky je v evidenci spotřebovaného materiálu nadbytek a pro některé naopak není spotřebován materiál žádný. Tyto nevyrovnané spotřeby pak mají vliv i na cenu prohlídek, které navíc po změně objemu balení změny svůj rozptyl.

ZÁVĚR

V průběhu vývoje zásadních částí této disertační práce v československém prostoru v dopravních podnicích provozujících městskou hromadnou dopravu byly stále využívány znalostní metody pro tvorbu plánů pravidelné i nepravidelné údržby a údržby po nehodách. Rovněž související rozpočty na výše uvedené typy údržby vznikaly znalostními metodami. Náklady na údržbu vozidel přitom představují významný podíl v nákladech dopravních podniků.

Cílem této práce tedy bylo navrhnout postup a algoritmy pro urychlení a zpřesnění procesů vedoucím k návrhům plánů údržby vozidel a souvisejících rozpočtů. Postup a algoritmy měly umožňovat kontrolu průběžných výsledků a uživatelské vstupy do procesů predikce nákladů, využití vozového parku a predikce výkonů jednotlivých vozidel. Stejně tak byl naplněn dílčí cíl vytvoření vstupů pro funkční plán skladových zásob zabezpečující z pohledu dopravce optimální spolehlivost údržby vozidel.

V práci je navržen obecný postup tvorby plánů údržby vozidel a určení nákladů na údržbu takovým způsobem, aby bylo dosaženo zrychlení a zpřesnění těchto procesů a ověřil je v praxi na vybraném dopravním podniku, kde byl navržený postup a algoritmy validovány a verifikovány ve své konkrétní podobě. Pro budoucí implementace a rozvoj autor poskytl v rámci případové studie praktické zkušenosti a návody na implementaci v provozním prostředí dopravních podniků.

V rámci navrženého postupu a algoritmů bylo částečně zachováno metod znalostních, ale bylo významně využito kombinací metod založených na zpracování dat a tradičních algoritmů. Stejně tak je v praxi nutné využít i metody praktické, resp. čištění dat.

S ohledem na využitelnost navrženého postupu a algoritmů v praxi pro československé prostředí jsou navrženy i kroky spočívající v zakomponování proměnných, které v této disertační práci byly opomenuty. Jejich výčet i místo vhodného zakomponování jsou v této práci jasně uvedeny.

Navržený postup využívá algoritmy, které jsou všechny implementované v dostupných knihovnách v jazycích R a Python a navržený systém tak může na jakémkoli dopravním podniku replikovat každý jen se základní znalostí programování a matematiky.

Na základě důkladného literárního přehledu je možné konstatovat, že navrhovaný postup a algoritmy jsou ve své kombinaci nové a originální. V dohledané literatuře není popsán žádný postup a algoritmy pro v této disertační práci požadované omezující podmínky a požadavky na říditelnost ze stran uživatelů systému.

Navržený postup a algoritmy jsou navrženy tak, aby neovlivnili stávající procesy přípravy dat a způsob jejich evidence. V případě zásadních změn v datové základně či způsobu evidence a sběru dat, resp. zpřesňování datové základny, i výsledky navrženého postupu a algoritmů budou přesnější.

Lze tedy konstatovat, že byla naplněna hlavní motivace vzniku této disertační práce, tedy vytvoření postupu a algoritmů, které by sloužili jako podpora manažerského rozhodování při plánování údržby vozidel a usnadnění kalkulace nákladů na údržbu plánovanou i neplánovanou. Stejně tak bylo Výsledek této disertační práce tedy může najít své uplatnění v praxi v dopravních podnicích provozujících městskou hromadnou dopravu v celém československém prostoru.

Pro shrnutí hlavní výhody navrženého postupu a algoritmů jsou:

- Zrychlení a zpřesnění tvorby plánu údržby plánované i neplánované
- Zrychlení a zpřesnění vyčíslení nákladů na všechny typy údržby včetně údržby po nehodách
- Využití odbornosti stávajících specialistů pro korekci průběžných výsledků a ovládnutí prediktivních modelů
- Vytvoření vstupů pro funkční plán skladových zásob zabezpečující z pohledu dopravce optimální spolehlivost údržby vozidel

POUŽITÁ LITERATURA

- [1] Adonyi, R., Heckl, I., & Olti, F. (2013, November). Scheduling of bus maintenance by the P-graph methodology. *Optimization and Engineering*, 14. doi:10.1007/s11081-013-9240-8
- [2] Alalawin, A., Arabiyat, L. M., Alalaween, W., Qamar, A., & Mukattash, A. (2021). Forecasting vehicle's spare parts price and demand. *Journal of Quality in Maintenance Engineering*, 27, 483-499. doi:10.1108/JQME-03-2020-0019
- [3] Al-Najjar, B. (1996). Total quality maintenance. *Journal of Quality in Maintenance Engineering*, 2, 4-20.
- [4] Apak, S. (2012). Spare part demand forecasting with Bayesian model. In *Uncertainty Modeling in Knowledge Engineering and Decision Making* (pp. 851-856). doi:10.1142/9789814417747_0136
- [5] Arena, F., Collotta, M., Luca, L., Ruggieri, M., & Termine, F. (2021). Predictive Maintenance in the Automotive Sector: A Literature Review. *Mathematical and Computational Applications*.
- [6] Armstrong, J. S. (2001). Evaluating Forecasting Methods. In J. S. Armstrong (Ed.), *Principles of Forecasting: A Handbook for Researchers and Practitioners* (pp. 443–472). Boston, MA: Springer US. doi:10.1007/978-0-306-47630-3_20
- [7] Arvan, M., Fahimnia, B., Reisi, M., & Siemsen, E. (2019). Integrating human judgement into quantitative forecasting methods: A review. *Omega*, 86, 237–252.
- [8] Baptista, M. S. (2018). Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers & Industrial Engineering*, 115, 41-53.
- [9] Basri, E. I., Abdul Razak, I. H., Ab-Samat, H., & Kamaruddin, S. (2017). Preventive maintenance (PM) planning: a review. *Journal of Quality in Maintenance Engineering*, 23, 114-143. doi:10.1108/JQME-04-2016-0014
- [10] Ben-Daya, M., & Duffuaa, S. O. (1995). Maintenance and quality. *Journal of Quality in Maintenance Engineering*, 1, 20-26.
- [11] Bjorklund, S.-P. M.-K. (2010). Developmental the maintenance plan: Maintenance activities on operational level. *7th International DAAAM Baltic Conference INDUSTRIAL ENGINEERING*, (pp. 22-24). Tallinn, Estonia.
- [12] Bousdekis, A. P. (2018). Enabling condition-based maintenance decisions with proactive event-driven computing. *Comput. Ind.*, 100, 173-183.

- [13] Box P., G. E. (2016). Time Series Analysis: Forecasting and Control, 5th Edition. *Journal of Time Series Analysis*, 37, 709-711. doi:<https://doi.org/10.1111/jtsa.12194>
- [14] Carvalho, T. P., Soares, F. A., & Vita, R. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137. doi:<https://doi.org/10.1016/j.cie.2019.106024>
- [15] Chambers, J. C., Mullick, S. K., & Smith, D. D. (1971). *How to choose the right forecasting technique*. Harvard University, Graduate School of Business Administration.
- [16] Chatfield, C. (2000). *Time-series forecasting*. CRC press.
- [17] Croston, J. D. (1972). Forecasting and stock control for intermittent demands. *Journal of the Operational Research Society*, 23, 289–303.
- [18] Dama, F., & Sinoquet, C. (2021). Analysis and modeling to forecast in time series: a systematic review. *CoRR*, *abs/2104.00164*. Retrieved from <https://arxiv.org/abs/2104.00164>
- [19] De Faria, H., Costa, J., & Olivas, J. (2015). A review of monitoring methods for predictive maintenance of electric power transformers based on dissolved gas analysis. *Renew. Sustain. Energy Rev.*, 46, 201-209.
- [20] Duffuaa, S. O., Ben-Daya, M., Al-Sultan, K. S., & Andijani, A. A. (2001). A generic conceptual simulation model for maintenance systems. *Journal of Quality in Maintenance Engineering*, 7(3), 207-219.
- [21] Everette S. Gardner, J., & Mckenzie, E. (1985). Forecasting Trends in Time Series. *Management Science*, 31, 1237-1246. Retrieved from <https://EconPapers.repec.org/RePEc:inm:ormnsc:v:31:y:1985:i:10:p:1237-1246>
- [22] Fan, J., & Gijbels, I. (2018). *Local polynomial modelling and its applications: monographs on statistics and applied probability 66*. Routledge.
- [23] Fildes, R., & Goodwin, P. (2007). Against your better judgment? How organizations can improve their use of management judgment in forecasting. *Interfaces*, 37, 570–576.
- [24] Friedler, F., Varga, B., & Fan, L. (1995). Decision-mapping: A tool for consistent and complete decisions in process synthesis. *Chemical Engineering Science*, 1755-1768.
- [25] Furch, J. a. (2010). *Opravy a zabezpečení materiálem bojových a speciálních vozidel. Část 4*. Brno: Univerzita obrany.
- [26] Garg, A., & Deshmukh, S. G. (2006). Maintenance management: Literature review and directions. *Journal of Quality in Maintenance Engineering*, 12, 205-238. doi:10.1108/13552510610685075

- [27] Ghajargar, M., Zenezini, G., & Montanaro, T. (2016). Home delivery services: innovations and emerging needs. *IFAC-PapersOnLine*, 49(12), 1371-1376.
- [28] Grall, A., Bérenguer, C., & Dieulle, L. (2002, Květen). A condition-based maintenance policy for stochastically deteriorating systems. *Reliability Engineering & System Safety*, p. 167/180.
- [29] Gutierrez, R. S., Solis, A. O., & Mukhopadhyay, S. (2008). Lumpy demand forecasting using neural networks. *International journal of production economics*, 111, 409–420.
- [30] Haarman H, D. G. (2004). *Value Driven Maintenance – New Faith in Maintenance: Mainnovation*. Dordrecht: Mainnovation.
- [31] Haghani, A., & Shafahi, Y. (2002). Bus maintenance systems and maintenance scheduling: model formulations and solutions. *Transportation research part A: Policy and Practice*, 36, 453–482.
- [32] Hammer, M., & Hershman, L. (2010). *Faster Cheaper Better: The 9 Levers for Transforming How Work Gets Done*. Crown Business.
- [33] Hendl, J. (2008). *Kvalitativní výzkum: základní teorie, metody a aplikace*. Praha: Portál.
- [34] Holt, C. C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International Journal of Forecasting*, 20, 5-10. doi:<https://doi.org/10.1016/j.ijforecast.2003.09.015>
- [35] Jardine, A. K., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483-1510.
- [36] Jezzini, A., Ayache, M., Elkhansa, L., Makki, B., & Zein, M. (2013). Effects of predictive maintenance(PdM), Proactive maintenace(PoM) & Preventive maintenance(PM) on minimizing the faults in medical instruments. *2nd International Conference on Advances in Biomedical Engineering*, (pp. 53-56). doi:10.1109/ICABME.2013.6648845
- [37] Khashei, M., Hejazi, S. R., & Bijari, M. (2008). A new hybrid artificial neural networks and fuzzy regression model for time series forecasting. *Fuzzy sets and systems*, 159, 769–786.
- [38] Kinney, W. R. (1978). ARIMA and Regression in Analytical Review: An Empirical Test. *The Accounting Review*, 53, 48–60. Retrieved from <http://www.jstor.org/stable/245725>
- [39] Kobbacy, K. A. (2008). *Complex system maintenance handbook*. Springer Science & Business Media.

- [40] Kumar, A., Shankar, R., & Lakshman, T. S. (2018). A big data driven sustainable manufacturing framework for condition-based maintenance prediction. *Journal of Computational Science*, 27, 428-439.
- [41] Lehder, G. (2000). *Teoria udržby a oprávv* (1 vydanie ed.). Košice: Strojnícka fakulta, Technická univerzita v Košiciach.
- [42] Lelo, N. A., Heyns, P. S., & Wannenburg, J. (2020, January 01). Forecasting spare parts demand using condition monitoring information. *Journal of Quality in Maintenance Engineering*, 26, 53-68. doi:10.1108/JQME-07-2018-0062
- [43] Lin, B., Wu, J., Lin, R., Wang, J., Wang, H., & Zhang, X. (2019). Optimization of high-level preventive maintenance scheduling for high-speed trains. *Reliability Engineering & System Safety*, 183, 261-275. doi:https://doi.org/10.1016/j.res.2018.11.028
- [44] Lolli, F., Gamberini, R., Regattieri, A., Balugani, E., Gatos, T., & Gucci, S. (2017). Single-hidden layer neural networks for forecasting intermittent demand. *International Journal of Production Economics*, 183, 116–128.
- [45] Lundgren, C., Skoogh, A., & Bokrantz, J. (2018). Quantifying the Effects of Maintenance - a Literature Review of Maintenance Models. *Procedia CIRP*, 72, 1305–1310.
- [46] Mira, L., Andrade, A. R., & Gomes, M. C. (2020). Maintenance scheduling within rolling stock planning in railway operations under uncertain maintenance durations. *Journal of Rail Transport Planning & Management*, 14, 100177.
- [47] Mirghani, M. (2001). A framework for costing planned maintenance. *Journal of Quality in Maintenance Engineering*, Vol. 7 No. 3, 170-182.
- [48] Moroz, S. (2005). Scientific Grounds of Ensuring Operational Safety of Vehicles. In *Dissertation for the academic degree of Doctor of Engineering*. Moscow.
- [49] Mukhopadhyay, S., Solis, A. O., & Gutierrez, R. S. (2012). The accuracy of non-traditional versus traditional methods of forecasting lumpy demand. *Journal of Forecasting*, 31, 721–735.
- [50] Nakajima, S. (1988). *Introduction to TPM: total productive maintenance*. Cambridge: Productivity Press.
- [51] Ni J, G. X. (2015). CIRP Annals. *Manufactured Technology*, 64, 447-450.
- [52] Pandher, S. S., Hossain, S., Budsaba, K., & Volodin, A. (2022). Efficient estimation method for generalized ARFIMA models. *Communications in Statistics - Theory and Methods*, 8515-8537.

- [53] Pang, B., Guo, S., Xiong, L., & Li, C. (2007). A nonlinear perturbation model based on artificial neural network. *Journal of Hydrology*, 333, 504–516.
- [54] Persaud, S. (1980). An overview of the seasonal adjustment of time series.
- [55] Pinçe, Ç., Turrini, L., & Meissner, J. (2021). Intermittent demand forecasting for spare parts: A Critical review. *Omega*, 105, 102513. doi:<https://doi.org/10.1016/j.omega.2021.102513>
- [56] Pinjala, S. K. (2006). An empirical investigation on the relationship between business and maintenance strategies. *International Journal of Production Economics*, 104(1), 214-229.
- [57] Pintelon L., P.-H. A. (2008). Maintenance: An Evolutionary Perspective. *Complex System Maintenance Handbook*, 21-48. doi:10.1007/978-1-84800-011-7_2
- [58] Rausand, M. (1998). Reliability centered maintenance. *Reliability Engineering & System Safety*, 60, 121-132.
- [59] Romeijnders, W., Teunter, R., & Jaarsveld, W. (2012). A two-step method for forecasting spare parts demand using information on component repairs. *European Journal of Operational Research*, 220, 386–393. doi:10.1016/j.ejor.2012.01.019
- [60] Saibannavar, D., Mallikarjun, M., & Kulkarni, U. (2020). A Survey on On-Board Diagnostic in Vehicles.
- [61] Sari, D. P., & Ridho, M. F. (2016). Jurnal Teknik Industri. 11, 73-80.
- [62] Sharma, R. e. (2005). FLM to select suitable maintenance strategy in process industries using MISO model. *Journal of Quality in Maintenance Engineering*, 11, 359-374.
- [63] Shin, J. H., & Jun, H. B. (2015). On condition based maintenance policy. *Journal of Computational Design and Engineering*, 2(2), 119-127.
- [64] Skřivánek, M. P. (1976). *Povozní spolehlivost a údržba strojů* (2 vydání ed.). Praha: SNTL-Nakladatelství technické literatury.
- [65] Stuchlý, V. (1988). *Údržba a opravy 2*. Praha: Nakladatelství dopravy a spojů.
- [66] Syntetos, A. A., & Boylan, J. E. (2001). On the bias of intermittent demand estimates. *International journal of production economics*, 71, 457–466.
- [67] Tealab, A. (2018). Time series forecasting using artificial neural networks methodologies: A systematic review. *Future Computing and Informatics Journal*, 3, 334-340. doi:<https://doi.org/10.1016/j.fcij.2018.10.003>
- [68] Tinga, T., & Loendersloot, R. (2019). Physical Model-Based Prognostics and Health Monitoring to Enable Predictive Maintenance: Advanced Methods, Decision Support

- Tools and Real-World Applications. *Predictive Maintenance in Dynamic Systems*, pp. 313-353.
- [69] Van den Broeke, M., De Baets, S., Vereecke, A., Baecke, P., & Vanderheyden, K. (2019). Judgmental forecast adjustments over different time horizons. *Omega*, 87, 34–45.
- [70] Varghese, V., & Rossetti, M. (2008). A parametric bootstrapping approach to forecast intermittent demand. *IIE Annual Conference. Proceedings*, (p. 857).
- [71] Verevkin, N. L. (2017). Method of Providing Safe Technical Condition of Vehicles by Technological Design of Enterprises. *Transportation Research Procedia*, 20, 665-670.
- [72] Virca I. and Badea, D. (2019). Study on the Predictive Maintenance of Vehicles and its Management Using the Specific “Keep the Machine Running” Application. *International conference KNOWLEDGE-BASED ORGANIZATION*, 25, pp. 291-297. doi:10.2478/kbo-2019-0048
- [73] Wang, W., & Syntetos, A. A. (2011). Spare parts demand: Linking forecasting to equipment maintenance. *Transportation Research Part E: Logistics and Transportation Review*, 47, 1194–1209.
- [74] Whittle, P. (1953). Estimation and information in stationary time series. *Arkiv för matematik*, 2, 423–434.
- [75] Willemain, T. R., Smart, C. N., & Schwarz, H. F. (2004). A new approach to forecasting intermittent demand for service parts inventories. *International Journal of forecasting*, 20, 375–387.
- [76] Winters, P. R. (1960). Forecasting Sales by Exponentially Weighted Moving Averages. *Management Science*, 6, 324-342. Retrieved from <https://EconPapers.repec.org/RePEc:inm:ormnsc:v:6:y:1960:i:3:p:324-342>
- [77] Wuest, T., Weimer, D., Irgens, C., & Thoben, K.-D. (2016). Machine learning in manufacturing: advantages, challenges, and applications. *Production & Manufacturing Research*, 4(1), 23-45.
- [78] Xinmin, Z., Wei, W., & Huizhi, R. (2016). Research on inventory control for equipment maintenance spare parts. In *Applied Engineering, Materials and Mechanics* (pp. 171-177). doi:10.1142/9789813146587_0027
- [79] Yin, R. K. (2017). *Case Study Research and Applications: Design and Methods*. SAGE Publications. Retrieved from <https://books.google.cz/books?id=6DwmDwAAQBAJ>
- [80] Yule, G. U. (1927). VII. On a method of investigating periodicities disturbed series, with special reference to Wolfer's sunspot numbers. *Philosophical Transactions of the*

Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character, 226, 267-298. doi:10.1098/rsta.1927.0007

- [81] Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
- [82] Zhou, R., Fox, B., Lee, H. P., & Nee, A. Y. (2004). Bus maintenance scheduling using multi-agent systems. *Engineering Applications of Artificial Intelligence*, 17, 623–630.