

Škoda Auto Vysoká škola o.p.s.

Studijní program:B6208 Ekonomika a management

Studijní obor/specializace: Logistika a management kvality

Využití nástrojů umělé inteligence pro predikci prostojů ve výrobních procesech v automobilovém průmyslu

Bakalářská práce

Ondřej Fidler

Vedoucí práce: Ing. Tomáš Malčic, Ph.D.



ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Zpracovatel: **Ondřej Fidler**

Studijní program: Ekonomika a management

Specializace: Logistika a management kvality

Název tématu: **Využití nástrojů umělé inteligence pro predikci prostojů ve výrobních procesech v automobilovém průmyslu**

Cíl: Cílem práce je navrhnout model pro predikci prostojů ve výrobních procesech v automobilovém průmyslu založený na nástrojích umělé inteligence a metodách strojového učení. Návrh modelu bude vycházet z analýzy historických dat o prostojích vybraného výrobního procesu. Výstupem práce bude identifikace příčin prostojů a návrh opatření pro jejich predikci a prevenci.

Rámcový obsah:

1. Vypracujte literární rešerši z oblasti Industry 4.0 a umělé inteligence.
2. Analyzujte současný stav vybraného výrobního procesu s důrazem na identifikaci frekvencí, příčin a následků prostojů.
3. Navrhněte model pro predikci prostojů ve výrobních procesech vycházející z analýzy historických dat a využívající nástrojů umělé inteligence a metod strojového učení.
4. Vyhodnoťte očekávaný přínos implementace navrhovaného prediktivního modelu a vypracujte návrh opatření pro předvídání a prevenci prostojů.

Rozsah práce: 25 – 30 stran

Seznam odborné literatury:

1. *Artificial intelligence in practice: how 50 successful companies used artificial intelligence to solve problems*. 1. vyd. John Wiley & Sons, Inc., 2019. 340 s. ISBN 978-1-119-54821-8 ..
2. SHAW, Greg; ARKAN, Çağlayan. *The future computed: AI & manufacturing / by Greg Shaw; foreword by Çağlayan Arkan*. Microsoft, 2019. 135 s. ISBN 9781074042066.
3. *The concept industry 4.0: an empirical analysis of technologies and applications in production logistics*. Springer Gabler, 2017. 150 s. BestMasters. ISBN 978-3-658-16501-7.

Datum zadání bakalářské práce: prosinec 2022

Termín odevzdání bakalářské práce: prosinec 2023

L. S.

Elektronicky schváleno dne 31. 5. 2023

Ondřej Fidler

Autor práce

Elektronicky schváleno dne 31. 5. 2023

Ing. Tomáš Malčic, Ph.D.

Vedoucí práce

Elektronicky schváleno dne 1. 6. 2023

doc. Ing. Jan Fábry, Ph.D.

Garant studijní specializace

Elektronicky schváleno dne 1. 6. 2023

doc. Ing. Pavel Mertlík, CSc.

Rektor ŠAVŠ

Prohlašuji, že jsem závěrečnou práci vypracoval(a) samostatně a použité zdroje uvádím v seznamu literatury. Prohlašuji, že jsem se při vypracování řídil(a) vnitřním předpisem Škoda Auto Vysoké školy o.p.s. (dále jen ŠAVŠ)směrnicí Vypracování závěrečné práce.

Jsem si vědom(a), že se na tuto závěrečnou práci vztahuje zákon č. 121/2000 Sb., autorský zákon, že se jedná ve smyslu §60 o školní dílo a že podle § 35 odst. 3 je ŠAVŠ oprávněna mou práci využít k výuce nebo k vlastní vnitřní potřebě. Souhlasím, aby moje práce byla zveřejněna podle §47b zákona č. 111/1998 Sb., o vysokých školách.

Beru na vědomí, že ŠAVŠ má právo na uzavření licenční smlouvy k této práci za obvyklých podmínek. Užiji-li tuto práci, nebo poskytnu-li licenci k jejímu využití, mám povinnost o této skutečnosti informovat ŠAVŠ. V takovém případě má ŠAVŠ právo ode mne požadovat příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to až do jejich skutečné výše.

V Mladé Boleslavi dne 28. 11. 2023

Obsah

Úvod	5
1 Průmyslová výroba	8
1.1 Úvod do výroby a výrobních systémů.....	8
1.1.1 Principy výrobního procesu	8
1.1.2 Výrobní systémy a jeho charakteristiky.....	9
1.1.3 Plýtvání a jeho formy v průmyslové výrobě	10
1.1.4 Efektivita práce a její měření	13
1.2 Průmysl 4.0	14
1.2.1 IoT – internet OfThings	15
1.2.2 Úvod do umělé inteligence (AI).....	16
2 Montážní linka ve společnosti Škoda Auto a.s.....	20
2.1 Analýza stavu montážní linky společnosti Škoda Auto.....	20
2.2 Popis montážní linky	21
2.2.1 Závěsný dopravníkový systém	21
2.2.2 Poruchovost dopravníkového systému.....	23
2.2.3 Sběr dat z montážní linky	24
3 Optimalizace stavu prostojů za pomocí prediktivní údržby.....	27
3.1 Výběr technologie pro prevenci defektů závěsného dopravníku	31
3.2 Návrh systému pro preventivní údržbu.....	32
3.2.1 Popis skladby a technologií systému	33
3.2.2 Trénování, optimalizace a validace modelu.....	33
4 Vyhodnocení systému prediktivní údržby.....	36
4.1 Vyhodnocení prediktivního systému.....	36
4.1.1 Parametry vyhodnocení prediktivního systému	36
4.1.2 Vyhodnocení simulační zkoušky	37
4.2 Budoucí směrování systému prediktivní údržby	38
Závěr	40
Seznam literatury	41
Seznam obrázků a tabulek	43

Úvod

Automobilový průmysl, jako jeden z klíčových pilířů světové ekonomiky, čelí neustálým výzvám v oblasti efektivity výrobních procesů a udržení konkurenčních schopností na globálním trhu. S rostoucí složitostí moderních výrobních technologií a narůstajícím tlakem na maximalizaci výkonu, se průmysl 4.0 a umělá inteligence (AI) stávají nepostradatelnými nástroji pro optimalizaci a inovaci v oblasti výrobních operací.

Tato bakalářská práce bude zkoumat a analyzovat význam využití nástrojů umělé inteligence pro predikci prostojů ve výrobních procesech automobilového průmyslu. Prostoj v produkčních linkách může být klíčovým faktorem ovlivňujícím celkovou efektivitu a produktivitu výrobního procesu. Využití umělé inteligence pro předpověď a prevenci těchto prostojů může znamenat zásadní zlepšení v řízení výrobních operací a optimalizaci celkového výrobního řetězce. Cílem je představit a analyzovat inovativní přístupy a metody, které umožňují efektivní využití umělé inteligence v rámci prediktivní údržby a optimalizace výrobních operací.

První kapitola této práce pečlivě rozpracuje obecný úvod do průmyslové výroby, s důrazem na klíčové trendy a koncepty spojené s moderními průmyslovými procesy. V rámci této kapitoly budeme podrobně analyzovat aktuální vývoj v oblasti průmyslu 4.0 a zkoumat jeho vliv na transformaci výrobních systémů. Zároveň se budeme věnovat základním principům výrobního procesu, charakteristikám výrobního systému a jeho klíčovým aspektům, abychom poskytli komplexní a hluboké pochopení této dynamické oblasti.

Průmysl 4.0 přináší nové dimenze automatizace, digitalizace a propojení v průmyslovém prostředí. Bude provedena analýza klíčových prvků tohoto konceptu, včetně internetu věcí (IoT), umělé inteligence a pokročilých analytických metod, které tvoří jádro moderní průmyslové transformace.

Rovněž budeme rozvíjet principy výrobního procesu a charakteristiky výrobních systémů, abychom odhalili základní mechanismy, které stojí za efektivním provozem průmyslových zařízení. Detailně se zaměříme na plýtvání a jeho různé formy v průmyslové výrobě, s cílem identifikovat oblasti, kde lze implementovat inovativní opatření ke snížení ztrát a zvýšení celkové efektivity.

Druhá kapitola této práce podstoupí důkladné zkoumání montážní linky ve společnosti Škoda Auto. Tato rozsáhlá sekce bude pečlivě analyzovat aktuální stav montážní linky, přičemž se zaměří na její strukturu, fungování a klíčové aspekty ovlivňující efektivitu celého výrobního procesu v tomto specifickém prostředí.

Analýza stavu montážní linky poskytne podrobný obraz aktuální situace výrobního prostředí Škoda Auto. Budeme se zaměřovat na jednotlivé složky montážní linky, s důrazem na závěsný dopravníkový systém, který hraje klíčovou roli v plynulém průběhu výrobních operací. Zvláštní pozornost bude věnována závěsnému dopravníkovému systému, jehož správná funkce je nezbytná pro bezproblémový průběh montážní linky. Analýza poruchovosti dopravníkového systému nám poskytne vhled do potenciálních problematických oblastí a umožní identifikovat možnosti pro jeho optimalizaci a zlepšení.

V rámci této kapitoly budeme rovněž zkoumat sběr dat z montážní linky. Tato část se zaměří na metody používané pro sledování výrobních procesů, sběr relevantních dat a jejich následnou analýzu. Tímto způsobem budeme schopni poskytnout komplexní pohled na fungování montážní linky ve společnosti Škoda Auto a identifikovat potenciální oblasti pro implementaci inovativních řešení v rámci optimalizace výrobních operací.

Třetí kapitola této práce předkládá podrobný pohled na optimalizaci stavu prostojů za využití prediktivní údržby. V rámci optimalizace stavu prostojů se zaměříme na konkrétní aspekty, jako je výběr technologie pro prevenci defektů v závěsném dopravníkovém systému. Tato část kapitoly bude zkoumat moderní technologické nástroje a strategie, které mohou být aplikovány na identifikaci a prevenci možných defektů a poruch ve fungování dopravníkového systému. Důraz bude kladen na inovativní přístupy, které mohou efektivně minimalizovat riziko prostojů a optimalizovat průběh výrobních procesů. Následně budeme přistupovat k návrhu systému pro preventivní údržbu, který bude speciálně přizpůsoben potřebám výrobní linky ve společnosti Škoda Auto.

Cílem této kapitoly je poskytnout systematický rámec pro využití prediktivní údržby ve specifickém výrobním prostředí společnosti Škoda Auto, s důrazem na

konkrétní opatření zaměřená na minimalizaci prostojů a optimalizaci výkonnosti výrobní linky.

Čtvrtá a závěrečná kapitola této práce bude zaměřena na důkladné vyhodnocení implementovaného systému prediktivní údržby ve společnosti Škoda Auto. Cílem této analýzy bude poskytnout komplexní pohled na dosažené výsledky, účinnost implementovaných opatření a přínosy, které tyto inovace přinášejí pro celkový výrobní proces společnosti.

Bude provedeno systematické hodnocení simulačních zkoušek systému prediktivní údržby. Simulace představují důležitý prostředek pro testování a optimalizaci systémů před jejich nasazením v reálném provozu. Budou analyzovány výsledky simulačních zkoušek s cílem posoudit schopnost systému předvídat a reagovat na potenciální problémy v prostředí montážní linky.

V závěru této kapitoly budou diskutována budoucí směřování systému prediktivní údržby ve společnosti Škoda Auto. Bude se zkoumat, jak lze dále zdokonalit a rozšířit systém v rámci neustále se měnícího prostředí automobilového průmyslu. Tímto způsobem bude kapitola poskytovat ucelený náhled na úspěch a perspektivy prediktivní údržby ve specifickém výrobním kontextu.

1 Průmyslová výroba

Úvod do teoretické části této bakalářské práce zahajuje první kapitola, v níž se hlouběji zabýváme výrobním procesem. Tato část nám poskytne vhled do definice výroby a souvisejících činností, a zároveň si vytvoříme pevný základ pro pochopení principů moderního průmyslu 4.0. Během této analýzy budeme zkoumat nejen samotné technologické a organizační aspekty výroby, ale i klíčové prvky, které formují současný průmyslový kontext. Základním cílem této teoretické části je poskytnout komplexní pohled na výrobu a připravit půdu pro následné hloubkové zkoumání konkrétního téma.

1.1 Úvod do výroby a výrobních systémů

Průmyslová výroba je klíčovým prvkem ekonomiky, kde suroviny a polotovary prochází řadou technologických procesů a transformací s cílem vytvořit finální výrobky nebo poskytovat specifické služby. Tento sektor hraje zásadní roli ve vytváření hodnoty a podporuje hospodářský růst. Průmyslová výroba může být nalezena v různých odvětvích, od těžkého průmyslu, jako je výroba oceli, po lehký průmysl, který zahrnuje výrobu spotřebního zboží. Moderní průmyslová výroba často využívá pokročilé technologie, automatizaci a informační systémy, což umožňuje efektivnější procesy a vyšší úroveň produktivity (Economy-Pedia, 2023).

Průmysl jako celek představuje širší oblast ekonomiky, zahrnující všechny činnosti spojené s výrobou, distribucí a obchodem s výrobky a službami. To může zahrnovat odvětví jako chemie, stavebnictví, energetika, potravinářství a mnohé další. Průmysl je nejen ekonomickým motorem, ale také klíčovým faktorem pro inovace a technologický pokrok. Změny v průmyslových odvětvích mohou mít významný dopad na celkový směr ekonomiky a společnosti, a proto je důležité sledovat a rozvíjet tento sektor s ohledem na udržitelnost a efektivitu. (INFOCUBE, 2021)

1.1.1 Principy výrobního procesu

V průmyslovém odvětví se termín "výroba" odkazuje na proces transformace surovin, komponent nebo materiálů do finálních výrobků, které mohou být prodány na trhu. Tento proces zahrnuje řadu operací, zařízení a postupů, které jsou navrženy tak, aby dosáhly efektivní a kvalitní výroby. Průmyslová výroba může být

velmi rozmanitá a zahrnovat různá odvětví, jako jsou automobilový průmysl, potravinářský průmysl, elektronika, chemie a mnoho dalších. Každé odvětví může mít své specifické potřeby a požadavky na výrobní procesy, ale základní principy efektivity, kvality a ekonomické udržitelnosti jsou společné pro většinu průmyslových odvětví (Keřkovský, 2012).

1.1.2 Výrobní systémy a jeho charakteristiky

V rámci výrobního systému se provádí výrobní proces jako soubor všech aktivit, které směřují k transformaci vstupů na výstupy v souladu s předem stanovenými specifikacemi. Klíčové prvky tohoto procesu zahrnují materiál a informace, které jsou charakterizovány tokem materiálu a informací. Aby podnik dosáhl základních předpokladů konkurenční úspěšnosti, musí dodávat vysokou kvalitu v přijatelných nákladech a vždy v "správný čas". Proto je klíčové správně nastavit organizační a materiální strukturu výrobního procesu (Jurová a kolektiv, 2016).

Výrobní procesy mohou být klasifikovány podle typu výrob na tři základní kategorie: sériová výroba, opakovaná výroba a zakázková výroba. Sériová výroba je charakterizována vytvářením většího množství identických výrobků, které jsou vyráběny ve velkých objemech a často s vysokou automatizací. Naopak opakovaná výroba se zaměřuje na výrobu menších sérií, ale stále s opakujícími se procesy, což umožňuje flexibilitu při zachování určitého standardu. V zakázkové výrobě je každý výrobek vyráběn na základě specifických požadavků zákazníka, což vyžaduje vyšší míru flexibility a individualizace výrobního procesu (Flídr a kolektiv, 2023).

Rozdíly v charakteru používaných technologií a organizaci výroby v jednotlivých typech výroby se projevují v struktuře a výši nákladů. V obecném smyslu platí, že výrobní zařízení s univerzální funkcionalitou jsou mnohostrannější a snadněji upravitelná, což usnadňuje jejich pořízení a modifikaci. Naopak však taková zařízení vykazují vyšší náklady na výrobu jednoho výrobku. V případě jednoúčelových linek jsou náklady na jeden výrobek obvykle nízké, avšak tato zařízení jsou méně flexibilní a obtížněji modifikovatelná. Navíc vytvoření plně automatizované výrobní linky přináší vysoké náklady. Každý z těchto přístupů má své výhody a nevýhody, a volba závisí na konkrétních potřebách a požadavcích daného výrobního procesu (Keřkovský, 2012).

1.1.3 Plýtvání a jeho formy v průmyslové výrobě

Plýtvání v průmyslu představuje jakékoli neefektivní či neefektivně využité zdroje, které vedou ke ztrátám produktivity a zvyšují náklady. Toto plýtvání může mít různé formy, včetně přebytečných skladových zásob, neoptimalizovaných výrobních procesů, nadměrného čekání na materiály nebo informace, nadbytečné produkce a zbytečných pohybů či přepravy. Efektivní identifikace a redukce těchto plýtvání jsou klíčové pro zlepšení celkové účinnosti a konkurenceschopnosti průmyslových podniků (TRADE MEDIA INTERNATIONAL, 2018).

Plýtvání je možné rozdělit na sedm oblastí, kde nejčastěji dochází k plýtvání, které jsou uvedeny v tabulce 1 (Jurová a kolektiv, 2016).

Tab. 1 - Sedm druhů ztrát

Typ plýtvání	Příklad
Nadprodukce	Příliš časté dodávky, příliš velké množství
Nadbytečné zásoby	Hromadění zásob ve skladech, krátkodobé skladы
Defekty	Špatná kvalita výrobku
Zbytečná manipulace	Přenos materiálu, neodladěný proces
Špatné zpracování	Nepožadovaná úroveň kvality
Čekání (prostoje)	Čekání na materiál, prostoje, úzká místa výroby
Transport	Složitost zásobování, špatná logistika

Zdroj: (Jurová a kolektiv, 2016)

Nadprodukce

Nadprodukce představuje stav, kdy je vyráběno nebo poskytováno více výrobků či služeb, než je skutečně požádáno na trhu. Tato situace může vést k nežádoucím následkům, jako jsou přebytečné zásoby, zvýšené náklady na skladování a potenciální finanční ztráty pro podnik. Nadměrná výroba často odráží nesoulad mezi nabídkou a poptávkou, což vyžaduje opatření k optimalizaci výroby a efektivnímu řízení zásob, aby byly minimalizovány negativní dopady na ekonomiku a konkurenceschopnost podniku (Švecová a Veber, 2021).

Nadbytečné zásoby

Neúměrná zásoba na skladě představuje situaci, kdy množství skladovaného zboží přesahuje aktuální poptávku nebo efektivní správu. Tento stav může být spojen s náklady na skladování, rizikem zastarání a blokací kapitálu. Efektivní řešení spočívá v eliminaci nadbytečných rezerv a provádění nákupů pouze v případě aktuální potřeby. Tímto způsobem se minimalizují zásoby na úroveň odpovídající aktuálním potřebám, což snižuje náklady na skladování a minimalizuje riziko ztráty hodnoty. Strategie eliminace rezerv a nákupu v reálném čase vyžaduje pečlivé sledování poptávky a rychlou reakci na změny na trhu, což přispívá k efektivnímu řízení zásob a optimalizovanému provozu (TRADE MEDIA INTERNATIONAL, 2018).

Defekty

Defekty v procesu výroby představují nežádoucí odchyly, chyby nebo nedostatky, které se objevují během výrobních operací a mohou ovlivnit kvalitu výsledného produktu. Tyto defekty mohou mít různé příčiny, včetně nesprávného nastavení strojů, chybějících kontrolních postupů, nedostatečného školení pracovníků nebo problémů s dodávkami surovin. Důsledky defektů zahrnují zvýšené náklady na opravy, reklamace, ztrátu reputace značky a snížení spokojenosti zákazníků. Efektivní řízení kvality a průběžné monitorování výrobních procesů jsou klíčové pro prevenci a minimalizaci defektů v průběhu výroby. Udržování vysokých standardů kvality nejen snižuje náklady spojené s odstraněním chyb, ale také posiluje důvěru zákazníků a upevňuje postavení podniku na trhu (Jurová a kolektiv, 2016).

Zbytečná manipulace

Zbytečná manipulace v procesu výroby označuje nadměrné nebo nepotřebné pohyby, úpravy nebo manipulace s materiály, výrobky nebo zařízením, které nejsou přínosné pro výsledný produkt. Tento druh plýtvání může zahrnovat nadbytečné přesuny materiálů, zbytečné úpravy na výrobní lince, časté změny uspořádání pracovních prostor nebo neoptimalizovanou manipulaci s výrobky. Zbytečná manipulace zvyšuje náklady na výrobu, může vést k fyzickému namáhání pracovníků a snižovat efektivitu výrobních procesů. Efektivní organizace pracovních postupů, optimalizace uspořádání pracovních prostor a

minimalizace nadbytečných pohybů jsou klíčové pro eliminaci tohoto typu plýtvání a zlepšení celkové efektivity výrobního procesu (Švecová a Veber, 2021).

Špatné zpracování

Špatné zpracování ve výrobním procesu v důsledku příliš sofistikovaného postupu může být úspěšně řešeno prostřednictvím identifikace zjednodušení a srovnání s konkrétními požadavky zákazníka. Analýza a identifikace klíčových aspektů příliš složitého procesu umožňuje nalezení oblastí, které mohou být zefektivněny a zjednodušeny. Důkladné srovnání technologických požadavků s očekáváními zákazníka umožňuje odstranění nesouladu a zaměření se na skutečné potřeby trhu. Implementace zjednodušení může zahrnovat optimalizaci operací, redukci nadbytečných kroků a přizpůsobení procesu tak, aby lépe odpovídalo skutečným požadavkům zákazníka. Tímto přístupem lze dosáhnout efektivity výroby, snížení nákladů a zlepšení celkové kvality výsledných produktů, přičemž se více soustředí na skutečné potřeby a očekávání zákazníka (TRADE MEDIA INTERNATIONAL, 2018).

Čekání (prostoje)

Čekání a prostoje ve výrobním procesu představují významné překážky, které mohou ovlivnit efektivitu a produktivitu podniku. Čekání může vzniknout v důsledku různých faktorů, včetně zpožděných dodávek materiálů, čekání na schválení nebo informace, a má potenciál zpomalit tempo výrobních operací. Prostoje, způsobené například poruchami strojů, údržbou nebo změnami ve výrobním procesu, mohou přerušit kontinuitu výroby a způsobit ztrátu produktivního času. Efektivní strategie pro minimalizaci čekání a prostoje zahrnují precizní plánování výrobních operací, optimalizaci dodavatelských řetězců, pravidelnou údržbu zařízení a implementaci rychlých opravných opatření. Tím lze maximalizovat využití zdrojů, snížit ztráty spojené s neplánovanými přestávkami a zajistit plynulý chod výrobního procesu (Jurová a kolektiv, 2016).

Transport

Plýtvání v oblasti dopravy v rámci výrobního procesu zahrnuje neefektivní pohyb materiálů či výrobků mezi různými pracovišti nebo lokalitami, což vede k nadměrným nákladům, ztrátě času a zbytečnému vytváření emisí. Toto plýtvání může vzniknout v důsledku neoptimálního uspořádání výrobních prostor,

nedostatečné koordinace přepravy, nepřiměřené velikosti objednávek nebo neefektivního nakládání s materiály. Pro eliminaci plýtvání v oblasti dopravy je nezbytné implementovat strategie, jako jsou optimalizace trasy přepravy, využívání moderních logistických technologií, minimalizace přemístění mezi pracovišti a strategické skladování materiálů tak, aby byly sníženy náklady, zlepšena efektivita a minimalizovány negativní environmentální dopady(Švecová a Weber, 2021).

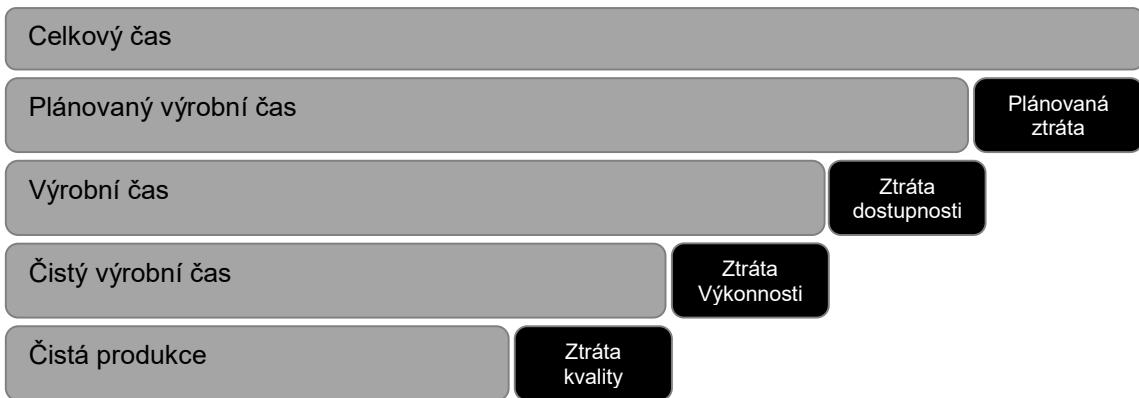
1.1.4 Efektivita práce a její měření

Efektivita práce ve výrobním procesu je kritickým faktorem pro dosažení optimálního výstupu při minimálním využití zdrojů. Měření efektivity práce v tomto kontextu zahrnuje sledování produktivity pracovníků, využívání strojů a zařízení, a dosahované kvality výrobků. Klíčové aspekty zahrnují analýzu výstupů na jednotku času, minimalizaci časových prostoje, a optimalizaci výrobních procesů. K měření efektivity se často využívá ukazatele jako OEE (Overall Equipment Effectiveness), který kombinuje dostupnost, výkon a kvalitu zařízení. Efektivní pracovní procesy, podporované školením zaměstnanců a pravidelným monitorováním, přispívají k dosažení vysoké úrovně efektivity ve výrobním prostředí, což v konečném důsledku posiluje konkurenceschopnost a zlepšuje celkovou výkonnost podniku(Flídr a kolektiv, 2023).

OEE – Overall Equipment Effectiveness

Jedná se o klíčový ukazatel, který poskytuje komplexní měření efektivity zařízení ve výrobním procesu. Tento ukazatel kombinuje tři hlavní faktory – dostupnost, výkon a kvalitu – a umožňuje získat celkový přehled o tom, jak efektivně jsou využívána výrobní zařízení. Dostupnost měří čas, po který je zařízení plně připraveno k provozu, výkon sleduje rychlosť zařízení v porovnání s jeho maximální kapacitou a kvalita hodnotí množství výrobků bez vad vzhledem k celkové produkci. Výpočet OEE jako součin těchto tří faktorů poskytuje procentuální hodnotu, která odhaluje úroveň efektivity výrobního zařízení. Monitoring OEE je klíčový pro identifikaci oblastí na zlepšení a optimalizaci výrobních procesů, což v konečném důsledku vede k maximalizaci produktivity a kvality (VORNE INDUSTRIES, 2023)

OEE je možné graficky znázornit se všemi jeho náležitostmi, jako výrobní čas, čistý výrobní čas a čistá produkce. Na každou tuto kategorii je nutné nahlížet separátně i jako na součást celku. Pro každou tuto kategorii je počítána ztráta, která je však pouze částečným ukazatelem a je nutné ji doplnit do výsledného vzorce. Toto vyjádření najdeme na obrázku 1.



Zdroj: (VORNE INDUSTRIES, 2023)

Obr. 1 - Grafické znázornění OEE

1.2 Průmysl 4.0

Výrobní průmysl v současnosti prochází obrovskými změnami. Tato změna je způsobena různými probíhajícími globálními megatrendy, jako je globalizace, urbanizace, individualizace a demografické změny, které v budoucnu značně ovlivní celé výrobní prostředí(Bartodziej, 2017, překlad autora).

S přínosem informačních technologií, kyberneticko-fyzikálních systémů a umělé inteligence do výroby, služeb a celého ekonomického sektoru dochází k zásadním transformacím v průmyslu a celé ekonomice. Důsledky těchto změn jsou natolik výrazné, že jsou označovány jako čtvrtá průmyslová revoluce. Několik rozvinutých zemí si již uvědomilo potenciál a rizika spojená s těmito transformacemi a aktivně podporuje čtvrtou průmyslovou revoluci prostřednictvím systematických opatření a speciálních programů. Klíčovým prvkem čtvrté průmyslové revoluce je spojení virtuálního kybernetického světa s fyzickou realitou. Toto spojení rovněž zahrnuje důležitou interakci těchto systémů s celkovou společností, tj. se sociálním světem (MINISTERSTVO PRŮMYSLU A OBCHODU, 2019).

Industry 4.0, též označovaný jako čtvrtá průmyslová revoluce, fundamentálně přetváří průmyslové procesy díky integraci klíčových technologií, mezi něž patří

Internet věcí (IoT), kyberneticko-fyzikální systémy a umělá inteligence (AI). Internet věcí hraje klíčovou roli v propojení fyzických objektů a zařízení s globální sítí, umožňujíc tak sběr a sdílení rozsáhlých datových sad. Tím vzniká možnost sledovat a řídit výrobní procesy s větší přesností a rychlostí. Kyberneticko-fyzikální systémy spojují digitální a fyzický svět, umožňujíc interakci mezi počítačovými algoritmy a fyzickými procesy v reálném čase. To vede k autonomnímu rozhodování zařízení a optimalizaci efektivity výrobních linek. Umělá inteligence zase umožňuje analýzu velkých objemů dat a strojové učení, což vede k zdokonalení predikce potřeb, řízení kvality a adaptace na dynamické změny v prostředí průmyslu. Tyto technologie společně tvoří klíčové pilíře Industry 4.0, které přinášejí nejen zvýšenou efektivitu, ale i nové možnosti pro inovace a konkurenceschopnost (Ustundag a Cevikcan, 2017).

1.2.1 IoT – internet OfThings

Internet ofThings (IoT) je termín, který označuje propojení fyzických zařízení a objektů s internetem, umožňující vzájemnou komunikaci a výměnu dat mezi nimi. Tyto zařízení jsou vybavena senzory, čipy a komunikačními moduly, což jim umožňuje shromažďovat a sdílet informace. IoT může zahrnovat širokou škálu objektů, od domácích spotřebičů a průmyslových strojů po nositelné technologie a chytré města (INSIDER INTELLIGENCE, 2023)

V nedávné době se Internet věcí (IoT) stal klíčovým technologickým prvkem 21. století. Propojení běžných předmětů, jako jsou kuchyňské spotřebiče, auta nebo termostaty, pomocí vestavěných zařízení umožňuje plynulou komunikaci mezi lidmi, procesy a věcmi. Díky cenově dostupným výpočetním prostředkům, cloudu, analýze velkých dat a mobilním technologiím mohou fyzické objekty sdílet a shromažďovat data s minimálním zásahem člověka. V tomto období hyperpropojenosti digitální systémy zaznamenávají, monitorují a přizpůsobují každou interakci mezi propojenými objekty. Fyzický a digitální svět se setkávají a spolupracují (Oracle, 2023)

Zavedení Internetu věcí (IoT) ve výrobě přináší revoluční změny v průmyslových postupech. Propojením zařízení, strojů a senzorů s internetem vytváří IoT inteligentní výrobní prostředí, které nabízí celou řadu výhod. Sběr a analýza dat v reálném čase umožňují průmyslovým podnikům lepší monitorování výrobních

procesů, diagnostiku zařízení a optimalizaci efektivity. Automatizovaná komunikace mezi zařízeními umožňuje rychlejší a přesnější reakce na změny v prostředí, což vede ke zvýšení flexibility výroby. Prediktivní údržba, podporovaná daty z IoT, umožňuje pravidelnou údržbu a minimalizaci časů odstávek.(Jurová a kolektiv, 2016).

1.2.2 Úvod do umělé inteligence (AI)

Umělá inteligence dává strojům schopnost vidět, slyšet, ochutnávat, čichat, dotýkat se, mluvit, chodit, létat a učit se. To zase znamená, že podniky mohou vyvinout zcela nové způsoby interakce se svými zákazníky, nabídnout jim mnohem inteligentnější produkty a služby, automatizovat procesy a zvýšit obchodní úspěch.Umělá inteligence dává prostor transformovat způsob komunikace mezi zákazníkem a podnikem. Získávání a zpracování potřebných dat umožňuje vytvářet inteligentnější a personalizované produkty a služby, které více odpovídají potřebám zákazníka (Marr a Ward, 2019).

„Když se někoho zeptáte, co rozumí pojmem „AI“, odpověď je často rámována tím, jak je tato technologie zobrazena ve sci-fi románech nebo hollywoodských trhácích. Ale stejně jako u mnoha technologií je realita umělé inteligence méně senzační a praktičtější, než si naše představivost myslí“ (Shaw, Arkan, 2019)

AI je v dnešní době jedním z oblastí technologie, která se dramaticky rozvíjí. Začíná ovlivňovat mnoho aspektů jak ve veřejném, tak soukromém životě. AI se v rámci digitální technologie definuje jako používání počítačového softwaru k vykonávání úkolů, které by obvykle vyžadovaly lidskou inteligenci. V užším smyslu se AI projevuje ve společnosti v mnoha formách. Rychlosť, jakou se tyto formy rozvíjejí, je značná: otázka již není, zda bude mít AI vliv, ale kde, u koho a kdy bude tento vliv vnímán pozitivně nebo negativně. (Hendl, 2021).

Definice umělé inteligence

AI je odvětvím počítačové vědy, které se zaměřuje na vytváření inteligentních strojů, schopných reagovat podobně jako člověk. Tato oblast úzce souvisí se strojovým učením a programováním počítačů. Termín AI poprvé použil americký informatik John McCarthy v roce 1956 v nadpisu žádosti o projekt konference. Během této konference byly představeny programy, které dokázaly hrát dámu nebo šachy, řešit různé teorémy a interpretovat texty. AI se snaží simulovat lidské

rozhodování pomocí počítače, kdy je počítač naprogramován k relativně samostatnému řešení určitého problému. To se děje prostřednictvím jednoduchých nebo komplexních algoritmů, které simulují "inteligentní chování," například když počítač funguje jako soupeř v šachové hře(Hendl, 2021).

Klíčové koncepty umělé inteligence

Umělá inteligence (AI) zahrnuje několik klíčových konceptů a technik, které umožňují počítačům simulovat inteligentní chování.

- **Strojové učení (Machine Learning, ML)**

Obecná AI je dnes často označována pod zajímavějším názvem strojové učení (ML). V čistě softwarovém smyslu je ML dvoufázový proces. Nejprve stroj trénujete, aby rozpoznával model v rozsáhlém datasetu, který simuluje skutečný tok dat. Poté tento model zpřístupníte pro použití softwarovou aplikací. Při každém volání klienta poskytnete vstup a obdržíte odpověď. Pokud je příliš mnoho odpovědí považováno za nedostatečné, musíte upravit model, modifikovat trénovací data a znova vytrénovat stroj. Tento iterativní cyklus zdůrazňuje dynamiku strojového učení, které se neustále vyvíjí a přizpůsobuje různým scénářům za účelem optimalizace výkonu. (ESPOSITO, 2020)

- **Neuronové sítě (Neural Networks)**

Neuronové sítě představují klíčový prvek umělé inteligence (AI), který simuluje strukturu a funkce lidského mozku. Tyto sítě jsou skládány z umělých neuronů propojených váhovými hodnotami, umožňujícími komunikaci mezi nimi. Každý neuron zpracovává vstupy, váží je podle příslušných vah a generuje výstup, který může být vstupem pro další neurony. Struktura neuronových sítí může zahrnovat různé vrstvy a architektury, a to díky čemu jsou schopny adaptovat se na komplexní vzory v datech a učit se z nich. V oblasti AI se neuronové sítě využívají pro řešení různorodých úkolů, jako je rozpoznávání obrazu, přirozený jazyk, predikce a další, přičemž jejich schopnost učení a adaptace je klíčovým prvkem pro dosahování vysoké úspěšnosti v těchto aplikacích(Hendl, 2021).

- **Rozpoznávání obrazu**

Rozpoznání obrazu je disciplínou umělé inteligence, která se zaměřuje na vývoj algoritmů a modelů schopných identifikovat a interpretovat vzory a objekty ve

vizuálních datech. Tato technologie umožňuje počítačům automaticky detektovat a klasifikovat objekty nebo scény na základě informací z obrázků nebo videí. V praxi se rozpoznání obrazu využívá v různých odvětvích, jako jsou automobilový průmysl pro autonomní řízení, medicína pro diagnostiku na základě zobrazovacích metod, nebo bezpečnostní systémy pro sledování a identifikaci osob. Moderní techniky rozpoznání obrazu často využívají neuronové sítě a hluboké učení, což umožňuje efektivní a přesné zpracování vizuálních informací (Shaip, 2023)

- **Deep Learning**

Deep Learning, česky hluboké učení, je větev AI, která využívá hlubokých neuronových sítí k modelování a interpretaci složitých datových vzorů. Tato technologie umožňuje automaticky extrahovat abstraktní funkce ze vstupních dat a hierarchicky je zpracovávat skrze více vrstev umělých neuronů. Deep Learning je klíčový pro úspěšné řešení náročných úkolů, jako je rozpoznávání obrazu, zpracování přirozeného jazyka, predikce a dalších aplikací, kde je potřeba schopnost komplexního učení a adaptace na rozmanité vzory v datech. Díky své schopnosti pracovat s velkými datovými sadami a hierarchickým zpracováním, hluboké učení představuje klíčový nástroj pro dosažení vysoké úspěšnosti v moderních aplikacích umělé inteligence (IBM, 2023)

Tvorba a učení algoritmu AI

Pro vytvoření algoritmu strojového učení je třeba projít několika kroky. Začíná to definováním problému, kde se zkoumají způsoby řešení, stanovují se hranice a zaměřuje se na základní formulaci problému. Po definici problému následuje úprava dat, protože každý problém strojového učení vyžaduje analýzu datové sady k nalezení řešení. V těchto datech může být skryto řešení nebo cesta k němu prostřednictvím analýzy strojového učení. Po úpravě a připravení dat pro algoritmus strojového učení následuje jejich předzpracování, což zvyšuje přesnost a zaměření konečného řešení. Teprve poté může být vytvořen samotný algoritmus. Program musí být strukturován tak, aby řešil daný problém, často imitující lidské kognitivní metody. Po dokončení této fáze je představena objektivní funkce, která činí algoritmus efektivnějším. Zatímco algoritmus detekující cíl bude mít za úkol detektovat cíl, objektivní funkce bude zaměřena na řešení problému v co nejkratším čase. Přenastavením objektivní funkce lze algoritmus specificky ladit

tak, aby nalézal řešení rychleji nebo přesněji. Algoritmus je následně trénován na vzorkovací sadě se základním plánem toho, co by měl dělat, s ohledem na objektivní funkci (Anirudh, 2022).

Typové rozdělení tréninkových metod

- **Supervizované učení (Učení s učitelem)**

Strojové učení se učí na základě známých historických dat, u kterých jsou jasně definované výsledky. Modely jsou učeny předpovídat správné výsledky. Následně jsou doplňována neznámá data, která jsou odhadována a následně manuálně korigována (po předem určený čas).

Podmínkou pro toto učení je známost správných definovaných výsledků, na kterých je možné učení provádět, bez prvotně vstupních správně vyhodnocených dat není možné takovýto model použít (Brown, 2021).

- **Nesupervizované učení (Učení bez učitele)**

Strojové učení se provádí na základě hledání shodných rysů (relevantních proměnných), ve shlukách, které nemají předem definovány výsledky. Takovéto učení je složitější, zabere více času a je celkově náročnější. Nicméně takovéto učení nám pomáhá při odhalení problematiky, kdy nemáme jasně zadané výsledky. Díky tomuto typu strojového učení jsme schopni vyhodnocovat zdánlivě nesrovnatelné shluky dat. Pro tento typ učení se používají hlavně dvě metody – shlukování a redukce. Shlukování slouží k roztrídění vstupů na základě podobnosti zadaných dat, redukce zase slouží pro vybrání správných, relevantních dat (Anirudh, 2022).

- **Posilované učení**

Strojové učení se provádí na základě interakce s prostředím a poučením se z výsledků. Takovýto model učení upravuje své chování podle zadané kladné či záporné odezvy na základě jeho interakce. Používají se dvě metody a to maximalizace odměny nebo minimalizace penalizace. Takovéto modely jsou často používány v oblasti umělé inteligence. Jsou schopny velice rychle a efektivně procházet scénáře a poučovat se z nich. Díky tomu jsou schopny předvídat budoucí vývoj scénářů a vybrat nejlepší strategii (Brown, 2021)

2 Montážní linka ve společnosti Škoda Auto a.s.

V průmyslovém světě se přístup k výrobě neustále vyvíjí, přičemž technologické inovace a moderní metody hrají klíčovou roli v zajištění efektivity, kvality a spolehlivosti výrobních procesů. Společnost Škoda Auto a.s., jako přední dodavatel a výrobce automobilů s dlouholetou tradicí a globálním vlivem se vyznačuje nejen svým závazkem k inovacím, ale také díky strategickému využití prediktivní údržby.

V dnešních dnech nacházíme situaci, kdy je klasická (periodická) prevence a opravy cestou reakce na situaci naprosto nedostačující. Z důvodů ztrát na čase ve výrobním procesu se postupně zavádí sofistikované senzory a monitorovací systémy, které sbírají data o stavu jednotlivých částí zařízení a linek, tak aby bylo možné vyvinout co nejsofistikovanější algoritmus pro preventivní údržbu. Tyto algoritmy zpracovávají vstupy (data) a umožňují predikci možných poruch nebo selhání komponent. Díky prediktivní údržbě jsme schopni provádět preventivní servisní zásahy v optimálních časech, minimalizovat neplánované prostoje a zajišťovat nepřetržitý chod výrobních linek. Tato strategie zvyšuje spolehlivost a bezpečnost výrobků co v konečném důsledku vede ke spokojenosti zákazníků.

2.1 Analýza stavu montážní linky společnosti Škoda Auto

Celý požadovaný projekt, který je zpracováván, je zaměřen na konkrétní montážní halu a jeden její montážní dopravník. Dopravník přepravuje za pomoci zavěšených závěsů s vlastním pohonem karoserie vozidel, na kterých probíhají montážní práce při kontinuálním provozu. Celková délka montážního dopravníku měří bezmála 1 kilometr a obsahuje přes 100 závěsů. Zařízení je řízeno automatizačním systémem (PLC), do kterého jsou zavedeny veškeré signály ze snímačů, informace z komunikačních rozhraní a informace o aktuálním stavu linky. Tyto data jsou následně vyhodnocována a na základě předem definovaného softwaru řídí PLC celý dopravníkový tok. PLC hlídá nejenom data od senzorů, zda jsou snímače sepnuty či nikoliv, nicméně v rámci sofistikovaných automatizačních celků jsou hlídány rychlosti jednotlivých klecí, rozestupy mezi vozidly a hlídány jejich polohy na celém dopravníku. Stejně tak jsou řízeny veškeré výhybky a zvedací celky, jelikož dopravníkový systém střídá různé úrovně.

Celá potřeba řešení problematiky tohoto dopravníku vznikla z důvodu zákazu přidávání olova do mědi. Olovo bylo tradičně přidáváno do mědi jako legura, která zvyšovala třecí vlastnosti. V technickém kontextu toto znamená, že došlo ke zhoršení třecích vlastností (nebylo dosaženo požadované hladkosti a snadnosti kluzu) měděných „uhlíků“ které se pohybují v měděné šíně. Toto vedlo k nárůstu prostojů, jelikož se začali vytvářet takzvané „špony“ které trčeli z měděných šín. Tyto špony byly schopny mezi sebou propojit různé fáze 3fázového napájení, což vedlo ke zkrátění a zastavování dopravníků, nicméně bez zjevných příčin, jelikož při zkratu došlo k přepálení „špony“ a dopravník bylo možné uvést znovu do chodu, bez nalezení příčiny. Dohledávání příčin zastavení na kilometrovém dopravníku není snadným úkolem, hlavně v momentě, kdy se jedná o nahodilé stavy, které nemají shodné místo, čas ani důvod. Nárůst prostojovosti byl navíc nenápadný a pomalý, jelikož docházelo k postupnému nahrazování komponent bez správných třecích vlastností za komponenty se správnými vlastnostmi. Toto znamenalo rozsáhlé bádání testování analýzy a vyhodnocování po příčinách zastavování dopravníku.

2.2 Popis montážní linky

2.2.1 Závěsný dopravníkový systém

Závěsný dopravníkový systém pro přepravu karoserií je speciální typ dopravníkového systému, fungující na principu ElektrifiedMonorailsystems. Jedná se o nosnou na dráhu, po které se pohybují závěsy, které převáží kusový materiál, v našem případě celé karoserie. Takovýto druh dopravníku umožňuje pohyb materiálu bez zabrání potřebné podlahové plochy. Tím zvyšuje efektivitu prostorového uspořádání a celého výrobního procesu.

Celý dopravník se skládá z následujících částí:

Nosná ocelová konstrukce

Ocelová konstrukce je základním stavebním prvkem, který nese celou váhu dopravníkového systému. Tato konstrukce je zhotovena z ocelových nosníků a profilů, které jsou navrženy a konstruovány tak, aby nesly a rozdělovali zatížení na různé body konstrukce. Ocelová konstrukce musí splňovat definované odolnosti na zatížení. Musí mít vysokou pevnost v tlaku, tahu a ohybu. Celá konstrukce je

navíc navrhována pokud možno modulově, tak aby bylo možné snadno konstrukci překonstruovat a upravit.

Hliníkový profil (dráha)

Hliníkový profil pro závěsný dopravník je klíčovým prvkem dopravníku. Tento profil je vyráběn na zakázku přímo pro konkrétní dopravníkový systém. Je vyroben z kvalitního hliníku, který má skvělé vlastnosti. Vyniká svou nízkou hmotností, zároveň však pevností a odolností vůči korozii. Hliníkové profily mají hladký povrch, který umožňuje snadný a plynulý pohyb nosných závěsů.

Nosné závěsy

Nosné jsou navrženy, konstruovány a vyráběny tak, aby byly schopny nést váhu celé karoserie a zároveň poskytovali možnost přesného řízení a polohování na dráze. Tyto závěsy musí být schopny uvést karoserii a pohybovat se sní po dráze po rovných úsecích, stoupání a skrze výtahy. Zároveň musí být konstruovány tak, aby nedomohlo dojít ke srážce.

Nosný závěs je konstruován pro danou dráhu a potřeby zákazníka. Závěsy jsou pevně spojeny, ale mohou obsahovat i pohyblivé části v různém rozsahu (naklápení / zvedání / otevřání / vyklápění)

Každý závěs se skládá z „páteře závěsu“ a „těla závěsu“. Na páteři je umístěno veškeré vybavení pro pohyb (pohonné vozíky, motory, převodovky, řídící a komunikační jednotky a sběrače) tělo se skládá z nosných ramen a mechanismů pro naklápení, zvedání, otevřání či vyklápění. Zároveň jsou zde umístěny RPS jehly které odpovídají otvorům v karoserii.

Řídicí systém

Celý dopravníkový systém je možné dodat od různých výrobců, nicméně každý se liší dle používané technologie a přístupu k celému systému. Společným prvkem je systém decentralizovaného řízení, které je rozděleno na část dráhy a na část vozíků. Každé z těchto řešení však přistupuje jinak k přenosu dat, řídícím povelům a zodpovědnosti za vykonávané úkony.

Řídicí systém dráhy ve většině případů zpracovává signály, které souvisí s dráhou, návaznými systémy (manipulátory a jiné technologie) které mohou ovlivnit chod celého systému. Zároveň zpracovává signály nouzových a

provozních zastavení, které jsou nutné z důvodu bezpečnosti pracovníků i strojů. Řídicí systém je složen z hlavního PLC a jeho periferií. Do periferií jsou zapojeny digitální, analogové vstupy či výstupy, odměřování poloh atd. tyto signály jsou za pomoci programu v PLC zpracovány a jejich výstupy jsou přenášeny na výkonné články systému. Stejně tak je každý stav možné vidět na vizualizaci, které je zpracována na ovládacích pultech či na centrálním dispečinku údržby.

Řídicí systém závěsu je složen z napájecí části, komunikační jednotky, řídící jednotky. Standardně je řídící jednotka postavena tak, že obsahuje vstupy, výstupy, jistící, spínací a výkonové prvky. Řídicí systém závěsu obsahuje svůj vlastní, předem definovaný program, dle kterého je řízen. Tento program vyhodnocuje aktuální stavy na závěsu a za pomocí komunikace s řídicím systémem dráhy stanovuje či upravuje svoje chování.

2.2.2 Poruchovost dopravníkového systému

Dopravníkový systém společnosti byl navržen a zkonstruován v 90. letech 20. století. Tento systém byl několikrát přestavován, rozšiřován a upravován. Na dopravníkovém systému byly modernizovány veškeré komponenty. V tuto chvíli je nasazena nejmodernější technologie, která je na trhu dostupná. Společnost si drží vysoký standardu s ohledem na automatizační technologii a to převážně z důvodu následků, které mohou být spojeny se zastaralou technologií. Zastaralá technologie přináší problematiku prostojů ve výrobním celku a jejich dopad do celkové produkce. Při frekvenci výroby jednoho vozu pod 60s se v celodenní produkci projeví jakékoli zastavení dopravníku. Takové to zastavení vede k prostoji na výstupu celého výrobního systému. V rámci potřeb stabilní a efektivní výroby je takovéto časy nutné definovat, a pokud je to možné zavést opatření pro jejich redukci.

Ve výrobním prostředí automobilového průmyslu se potýkáme s prostoji způsobenými mnoha vlivy. Jedním z možných dělení je prostoje plánované a neplánované. Toto nám definují výrobní možnosti, které jsme schopni zabezpečit. Plánované prostoje jsou přerušení výroby, která jsou pečlivě řízena a hlídána. Takové prostoje je možné plánovat a vymýšlet strategie a opatření proti jejich aplikaci. Může se jednat například o změny výrobního procesu, nedostatek určitých komponent či školení personálu. Pro nás jsou však důležité prostoje

neplánované, jelikož takovéto prostoje není možné předem snadno definovat. Takovéto prostoje dělíme na prostoje způsobené obsluhou, nebo prostoje způsobené technologií.

Prostoje způsobené obsluhou jsou situace, kdy dochází k dočasnému přerušení výrobního procesu z důvodu lidské intervence nebo obsluhy. Tyto prostoje mohou mít různé příčiny, ale obvykle jsou spojeny s potřebou obsluhy. Jedná se především o nedodržení pracovních postupů, chyb operátorů v průběhu montáže, nebo dalších činností vyžadujících lidský zásah. Takovéto prostoje je možné redukovat plánovaným školením obsluhy, tak aby zaměstnanci byli adekvátně školeni a informováni o nových postupech, technologiích nebo bezpečnostních opatřeních.

Prostoje způsobené technologií mohou v procesu výroby vznikat z důvodu nečekaných událostí v rámci technického stavu zařízení. Do technického stavu zařízení je možné zařadit mechanické problémy, zejména vlivem opotřebení, komplikace elektrických komponent – selhání komponent či chybu v softwarových aplikacích. Takovéto prostoje mají významný dopad na celý výrobní proces, protože není předem možné definovat rychlosť odstranění takovéto závady. V případě mechanických problémů je nutné odstranit závadu, v případě nutnosti závadu opravit či znova naladit mechaniku celého celku, v případě elektrických komponent musí dojít k výměně vadných komponent a jejich vlastnímu nastavení. V případě chyb softwaru je nutné chybu napravit, případně ošetřit, tak aby nebyla možnost opakování takové chyby. Všechny tyto prostoje však mají jednoho společného jmenovatele, kterým je identifikace. V případě, že dojde k zastavení stoje je jako první a nejdůležitější identifikovat a hlavně správně definovat nastalou situaci. Například v případě nefunkčního snímače se nemusí jednat o chybu snímače, nicméně o mechanické slazení všech komponent. Stejně tak chybu softwaru může vyvolat souhra nastalých situací – například chyba vyhodnocení kamery může být způsobena nepředvídanými světelnými podmínkami.

2.2.3 Sběr dat z montážní linky

Hlavní prvotní sběr dat ve společnosti provádí dispečink údržby, který disponuje centrální vizualizací, ve které jsou zaznamenávány veškeré stavy dopravníkové systémy. Každý snímač i každý výkonný člen dopravníku přenáší své informace

několikrát za sekundu do řídicího systému, který je dále předává do uživatelského rozhraní, které slouží pro sledování stavu výroby (z pohledu nutnosti zásahu údržby). Dispečer v návaznosti na zobrazenou vizualizaci reaguje na podměty a řídí tok karoserií či pracovníků údržby. V případě prostojů se zde schází pohled ze strany technologie s výpovědí pracovníka údržby, který nastalou situaci prostoje řešil. Výstupem z dispečinku je přehled produkce, která byla požadována a která byla naplněna. Dále se z reportu dozvíme čas, ve který se porucha stala, jejich dobu trvání a popis nastalé situace. Takováto data jsou prvním výchozím krokem k definování potřeb pro zvýšení efektivity produkce.

Tab. 2 – Přehled využitelnosti linky

	Noční	Ranní	Odpolední	celkem
Takt (sec)	59,0	59,0	59,0	
Kapacita (vozy)	400	400	400	1200
Plán (vozy)	380	380	380	1140
Vyrobeno (vozy)	385	373	380	1138
Využitelnost (%)	100%	98,16%	100%	99,82%

Tab. 3 – přehled prostojů linky za uplynulé směny

Čas	Trvání	Linka	Zařízení	Popis prostoje
06:15	2	EHB	Zvedák A15	Chyby koncové polohy (přejetí)
11:38	3	EHB	Závěs 40	Výpadek měniče
13:11	2	EHB	Zvedák B3	Nouzový stop – chyba obsluhy (narušení světelné závory)

Výstupy z dispečinku údržby slouží pro rychlý přehled vedoucím a zodpovědným pracovníkům za proces výroby. V rámci takovéhoto přehledu je možné upravit výrobní plány, případně zařídit nutné okamžité kroky k nápravě nastalých situací.

Mezi takovéto kroky se řadí plánování preventivní údržby, technické analýzy nastalých problémů či personální opatření. Každý z těchto kroků slouží k zaručení využitelnosti zařízení, k udržení efektivního chodu a zabránění ztrátám způsobeným prostoji.

3 Optimalizace stavu prostojů za pomocí prediktivní údržby

V určitém období životnosti dopravníku došlo k jeho obnově a výměně měděných trolejí s příměsí olova za troleje bez této příměsi. Toto vedlo k vysokému nárůstu prostojů, které se jevili jako nahodilé a nesouvisející. Dopravníkový systém zastavoval na poruchy napájení v různých částech svého toku, nicméně bez zjevné příčiny. Dopravníkový okruh bylo možné znovu zprovoznit v řádu několika minut, nicméně bez nalezení příčiny. Při výskytu několika těchto prostojů během jednoho výrobního dne se hledala a analyzovala příčina, od projití zapojení jednotlivých závěsů, po zkoumání jištění až po výměny různých komponent. Jediným jasným vodítkem byla spálenina v trolejovém vedení. Po několikatýdenním sledování a analýze dat byla nalezena příčina a to ve tvorbě vlasových špon. Tyto špony při dosažení určité délky a specifickém průjezdu závěsu způsobili propojení fází napájecího okruhu.

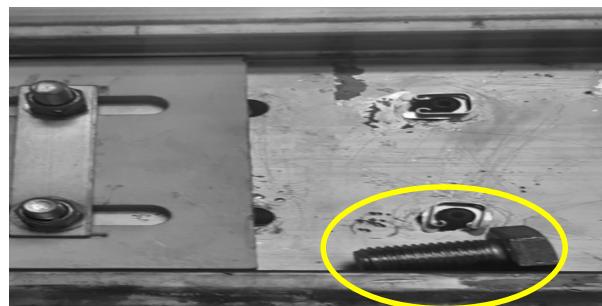
Takovéto propojení vedlo k zastavení dopravníkového systému a vyhlášení poruchy. Jelikož se však jednalo o vlasové špony, tak tato špona byla při zkratu spálena a nebyly nalezeny její zbytky, pouze slabě opálené místo. Takováto místa však byla typická, jelikož i při průjezdu závěsu může dojít k zajiskření mezi trolejí a přenosovým „uhlíkem“. Výsledkem celkové analýzy problematiky zastavování dopravníku byla potřeba lepší diagnostiky celého trolejového vedení dopravníkového systému.

V rámci již vzniklé analýzy bylo možné definovat jeden z hlavních cílů, které by měl zajistit systém preventivní kontroly – kontrola a včasné odhalení tvorby vlasových špon. V rámci hledaného řešení se nabízelo rozšířit spektrum potřeby o úkony, které je možné predikovat také. Konkrétně se jednalo o povolené, prasklé nebo chybějící šrouby a matice profilů, komplexní pohled na instalační prvky v profilu, poškození profilů či jejich opotřebení, mezery mezi profily a jejich souosost, cizí předměty v profilech či praskliny. Tyto vady byly rozděleny do dvou kategorií a to dle místa defektu. Dělíme je na defekty hliníkového profilu a defekty napájecích šín. V podstatě je rozdělení řešeno podle nutnosti zásahu, zda je nutný zásah pracovníka údržby zodpovědného za mechaniku, či pracovníka zodpovědného za elektro.

Vady hliníkového profilu

Povolené, prasklé či chybějící šrouby, cizí předměty v profilech

Na obrázku 2 vidíme vady vznikající z důvodu chyb v instalacích pracích – nesprávné utažení šroubového spoje (špatný utahovací moment, chybný úhel) – či z důvodu chvění ocelové konstrukce. Chvění ocelové konstrukce způsobuje rázy do šroubových spojení, které může způsobit povolení a je tedy nutné provádět pravidelnou kontrolu. Tato kontrola je definována výrobcem zařízení, který stanovuje četnost a postup kontrol.



Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr.2Cizí předmět v hliníkovém profilu

Poškození profilů, opotřebení

Na obrázku 3 vidíme opotřebení profilu, ke kterému dochází v rámci standardní produkce, vlivem tlaku, mechanických nárazů nebo tření. Opotřebení není řazeno mezi kritické vady, nicméně je nutné hlídat rozsah poškození. V rámci závažnosti poškození je nutné definovat preventivní kroky pro nápravu stavu.



Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr.3Opotřebení dráhy – rýha v hliníkovém profilu

Mezery mezi profily

Na obrázku 4 vidíme mezery mezi profily, které jsou způsobeny vadnou instalací dodavatele nebo teplotními rozdíly v průběhu roku. Teplotní roztažnost může způsobit problémy hlavně v místech, kde dochází k napojování pohyblivých částí dopravníku (výhybky, výtahy). V případě malé mezery může dojít k poškození celého profilu (zkřížení, sražení). V případě mezery velké dochází ke skokovým rázům, které mohou způsobit poškození napájecí soustavy (zlomení uhlíků). Obě tyto situace vedou k rozsáhlému prostoji, jelikož je nutný okamžitý zásah údržby.



Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr.4 Špatně nastavená dilatace spáry mezi profily

a. Praskliny hliníkového profilu

Na obrázku 5 můžeme vidět praskliny, které mohou vzniknout z příčiny opotřebení, chyby v materiálu, teplotní změny či změny mechanického napětí. Každou vzniklou prasklinu je nutné sledovat a naplánovat preventivní zásah.



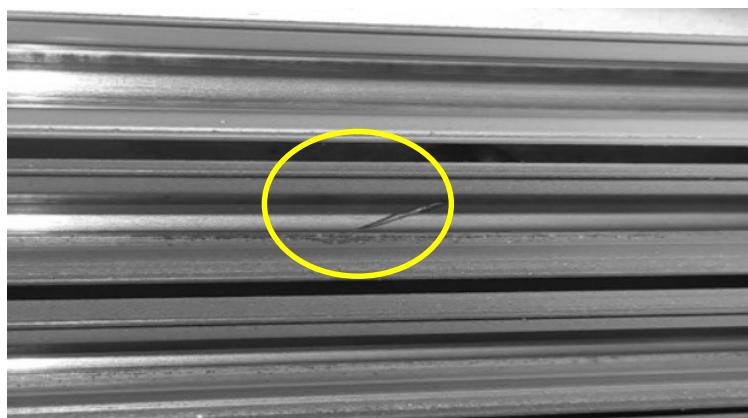
Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr.5 Rozsáhlé praskliny hliníkového profilu

Vady napájecích šín

Špony v šínách

Na obrázku 6 je zobrazena vlasová špona. Špony v šínovém systému vznikají z důvodu tření sběračů o povrch šín. Takovéto tření je nežádoucí, nicméně vzniká z důvodu únavy materiálu či špatného nastavení přítlačných rámů sběračů. Vzniklé špony mohou způsobit komplikace a prostoje například z důvodu propojení 2 fází napájecí soustavy.

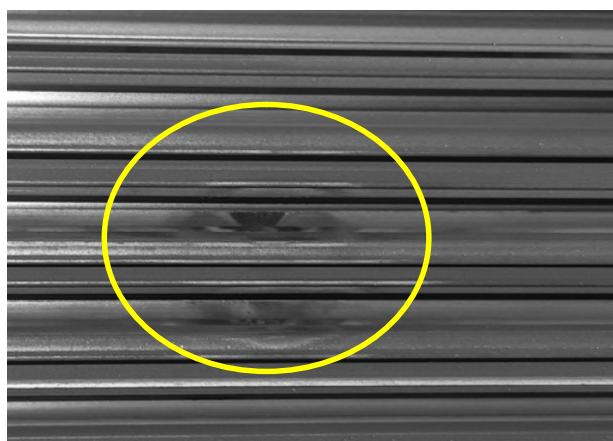


Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr. 6 Špona v šínovém systému

Poškození, opotřebení

Na obrázku 7 je vidět příklad opotřebení šínového systému, ke kterému dochází v rámci standardního provozu. Poškození může vzniknout díky opotřebování uhlíků či nestandardním stavům zařízení.

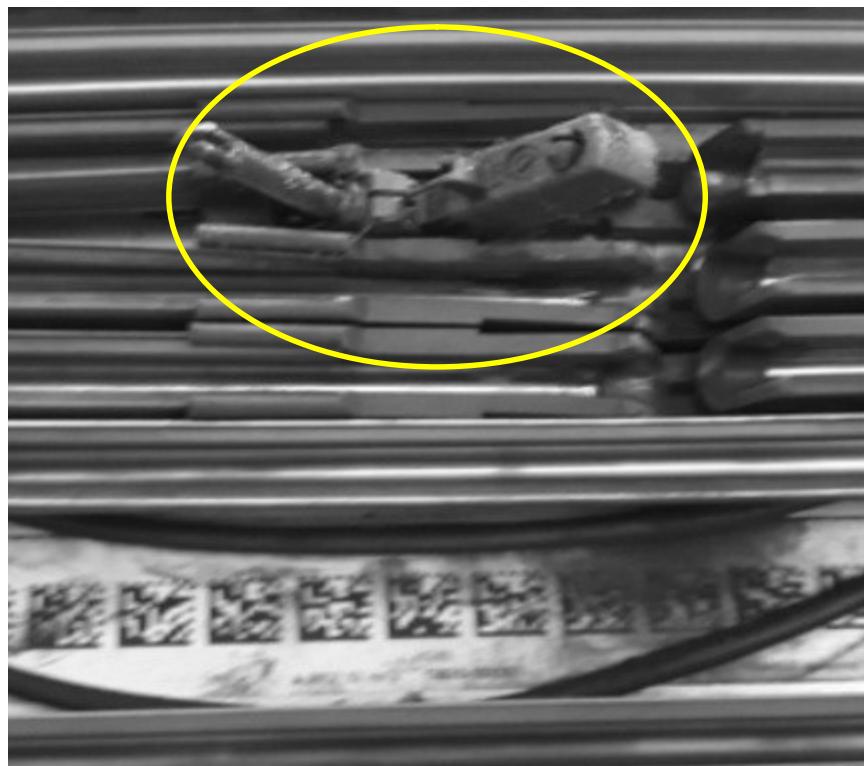


Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr. 7 Opotřebení šínového systému

Cizí předměty v šínách

Na Obrázku 8 můžeme vidět cizí předmět v šíně. To může být způsobeno okolním prostředím, špatným stavem komponent závěsu či nestandardním chováním zařízení – selhání odměřovacího systému a následná srážka závěsu.



Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr.8 Cizí předmět v šínovém systému

3.1 Výběr technologie pro prevenci defektů závěsného dopravníku

Při výběru technologie pro prevenci defektů závěsného dopravníku je nezbytné pečlivě promýšlet každý krok. Aby bylo dosaženo efektivního výkonného systému je nutné přihlížet nejen k vlastní technologii, ale také k provozním podmínkám, ve kterých bude systém nasazen. Prvním klíčovým krokem je definice konkrétních požadavků na systém. V tomto směru jsme měli několik možností.

Senzory a Monitoring:

Instalace senzorů pro sledování klíčových parametrů, jako jsou vibrace, teplota, odběry a zatížení v kritických částech dopravníku. Tento případ již byl ošetřen systémem FIOT který zajišťuje condition monitoring celého zařízení z pohledu standardního chování mechanických a elektrických částí dopravníku.

IoT a Cloud Computing:

Propojení závěsného dopravníku s internetem věcí (IoT) pro sběr a analýzu dat v reálném čase. Data jsou ukládána v cloudu, což umožňuje centralizovanou analýzu a plánování údržby. Takovéto řešení připadalo v úvahu, nicméně pro naši problematiku chyběl vyhodnocovací článek. Takovéto řešení je možné pro aktivní sběr dat, nicméně mu chybí centrální mozek, který by celé vstupní datové spektrum vyhodnocoval.

Strojové Učení a Predikce:

Využití strojového učení pro analýzu historických dat a predikci možných budoucích defektů. Algoritmy mohou identifikovat vzory, které naznačují potenciální problémy a včasně varovat. Takovéto řešení vypadalo ideální, nicméně v rámci rozsahu celého dopravníku chyběla historická data.

Při rozhodování o místě snímání dat je nutné identifikovat strategická místa, kde bude umístěno vybavení. Při zohlednění různých technologií jsme schopni navýšit naše možnosti. Například technologie edgecomputing umožnuje provádět část analýz přímo na senzorech, což sníží latenci celého systému a zvýší přenosové rychlosti. Integrace rozpoznávání obrazu s pomocí umělé inteligence přináší možnost rozpoznávání vzorů a identifikaci vad přímo v konečném zařízení a okamžité rozhodování.

3.2 Návrh systému pro preventivní údržbu

Tak jako to bývá vždy, nebylo možné jít pouze jednou cestou a bylo nutné správně nastavit kombinaci více systémů. Pro náš případ byla zvolena kombinace všech výše zmíněných, z každé oblasti jsme si vybrali část, která pokrývá naše potřeby. Díky této kombinaci jsme navrhli systém, který slouží pro monitoring systému v reálném čase, přímo na zařízení vyhodnocuje sesbíraná data a výsledky ukládá na server.

Technologie systému

- Sběr dat pomocí 6 monitorovacích kamer
- Vyhodnocení přímo na zařízení (Edgecomputing)
- Rozpoznání obrazu pomocí AI (Hluboké, strojové a neuronové sítě)
- Zpracování a vizualizace vyhodnocených dat (Cloud computing)

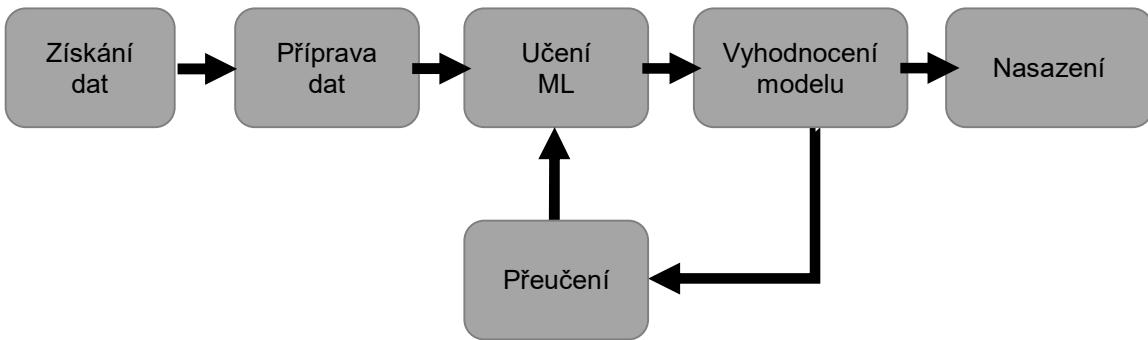
3.2.1 Popis skladby a technologií systému

Řešení sběru dat za pomocí kamerového systému splňovalo naše požadavky na kvalitu sběru dat a zároveň splňovalo naše potřeby. Ke zvolenému kamerovému systému bylo nutné zvolit správnou technologii potřebnou k rozpoznání, zpracování a vyhodnocení. Pro správné zpracování našich potřeb byla zvolena kombinace technologie edgecomputing s rozpoznáváním obrazu pomocí umělé inteligence a technologie cloud computing. Tato kombinace je schopna vytvořit komplexní systém pro zpracování a analýzu obrazových dat.

Technologie edgecomputing nám dává možnost rychlé a distribuované analýzy dat přímo na zařízení (závěsu). Edgecomputing přenáší výpočetní zátěž a rozhodovací procesy k datům, to nám eliminuje potřebu trvalého přenosu rozsáhlých datových sad do síťového cloutu. Toto nám pomáhá dosáhnout efektivní reakce na místně události. Díky tomu jsme schopni rychle rozpoznat anomálie a provést preventivní kroky k vyhodnocení závažnosti situace a navolení nejlepší strategie prevence. Pro rozpoznávání objektů ve snímaných snímcích je používán algoritmu YOLO ver. 5.0.5. který nám umožňuje detekci objektů v jednom průchodu, což zajišťuje detekci v reálném čase. Díky tomu jsme schopni provádět rychlou a efektivní analýzu vizuálních dat. Cloud computing poskytuje prostředí pro trénování a nasazení našich složitých modelů s využitím výpočetní sily dostupné ve virtuálních prostředích. Toto využíváme k tvorbě a optimalizaci prediktivního modelu, což přispívá k vyšší přesnosti. Díky cloudové architektuře jsme schopni provádět trénování našich modelů a následně je aplikovat v reálném prostředí.

3.2.2 Trénování, optimalizace a validace modelu

Prvním krokem pro zprovoznění celého systému bylo osazení celého zařízení na dopravníkový závěs a jeho spuštění a odladění po mechanické a elektrické stránce. Při funkčním celku navrhnutého zařízení bylo možné přejít k prvním průjezdům a získávání prvních vzorků sbíraných dat. Na obrázku 9 můžeme vidět klasický postup strojového učení.



Obr. 9 Princip strojového učení

Vzorkové data byly následně řádně vyhodnoceny, klasifikovány, a roztržiděny do kategorií dle potřeby celého modelu. Byly určeny 3 kategorie získaných dat. Dle relevance byly rozděleny na data testovací, trénovací či validační. Každé tyto data slouží ke specifickému kroku v průběhu optimalizace a validace modelu.

Trénovací data

Jedná se o data s jasně definovanou vadou, kterou musí systém odhalit. V našem případě se jednalo o simulaci poruch, které na dopravníku mohou vznikat. Data byla vytvořena průjezdem závěsu přes schválně nasimulovanou chybu. Takovýto vzorek byl následně vyfiltrován příslušně označen a vyhodnocen. Těmto datům se snaží model přizpůsobit a naučit se vztahy mezi vstupními a výstupními proměnnými.

Validační data

Jedná se o data, které nebyly použity během trénování a které model ještě neviděl. Tyto data jsou použita k hodnocení výkonnosti modelu na nových, neviděných datech a slouží k optimalizaci parametrů celého modelu. Validační data pomáhají zajistit, že se model chová dle potřeb a není spjatý pouze s trénovanými daty.

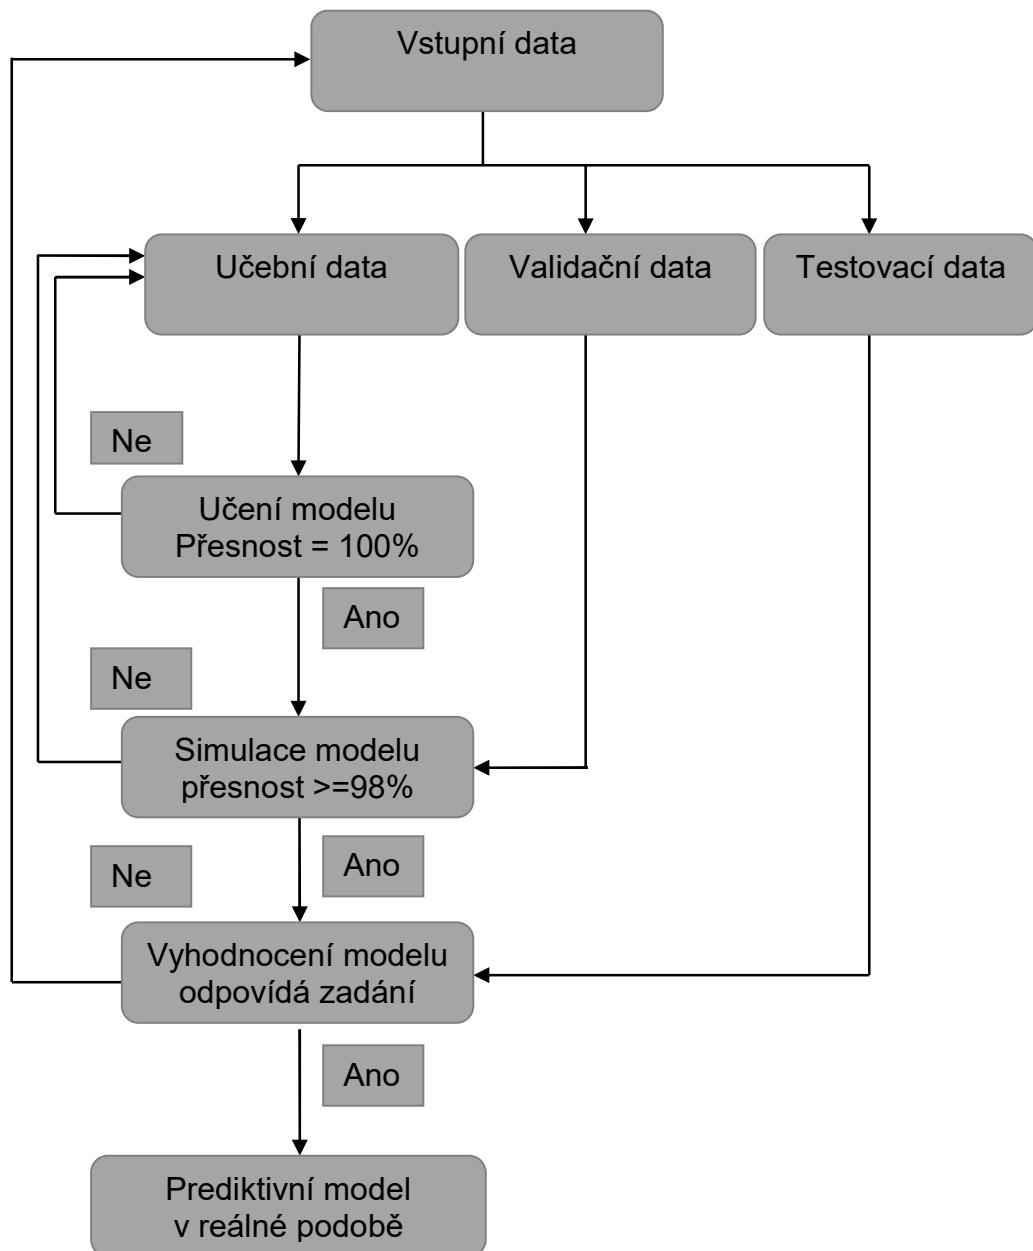
Testovací data

Jedná se opět o data, která nebyla použita v žádném předchozím vzorku a slouží pro finální otestování celého modelu po dokončení vývoje celého systému. Takováto data jsou specificky vybrána a použita, tak aby bylo možné změřit finální výstup a bylo možné hodnocení výkonnosti celého modelu. Testovací sada poskytuje objektivní měření schopnosti modelu přizpůsobit se na nová data.

Trénování modelu

Trénování modelu v našem případě probíhalo za pomocí neuronové sítě. Jedná se o proces, při kterém se stanovují váhy sítě, které jsou porovnávány se správnou sadou dat, tak aby došlo k minimalizaci chyby mezi predikcemi modelu a skutečnými hodnotami. V našem případě byly váhy dat nastaveny manuálně dle našich potřeb a následně byla jejich přesnost učena na vzorcích trénovacích dat.

Na obrázku 10 můžeme vidět práci s datovým tokem v rámci strojového učení v našem modelu.



Obr. 10 Blokové schéma učení prediktivního systému

4 Vyhodnocení systému prediktivní údržby

Vyhodnocení a validace našeho prediktivního údržbového modelu probíhá prostřednictvím validační zkoušky, kde jsou simulovány a definovány defekty, aby byla otestována reakce celého systému. Tato simulace představuje klíčový krok k zajištění robustnosti a spolehlivosti celého systému v reálných podmínkách. Tímto způsobem získáváme hlubší pochopení chování modelu vůči nežádoucím faktorům nebo neočekávaným situacím, což nám umožňuje identifikovat potenciální slabiny a provést další optimalizace či úpravy. Simulace defektů slouží k identifikaci potencionálních slabých míst v modelu a umožňuje nám provádět potřebné úpravy a optimalizace. Předpokládáme, že výsledky této zkoušky nám poskytnou podrobné informace o stavu vyhodnocení jednotlivých vad a současně umožní testování chování celého systému v reálném prostředí automobilového průmyslu. Celkově nám to poskytne důvěru ve spolehlivost a odolnost celého našeho prediktivního údržbového systému v proměnlivém provozním prostředí.

4.1 Vyhodnocení prediktivního systému

V rámci našeho vyhodnocení prediktivního systému pečlivě analyzujeme jeho výkonnost a schopnost předvídat a předejít potenciálním problémům v dopravníkovém celku. Sledujeme účinnost předpovědí defektních stavů, schopnost identifikace anomalií a celkovou spolehlivost systému. Průběžně porovnáváme naše predikce s reálnými událostmi a validujeme výsledky na základě historických dat. Důkladné vyhodnocování našeho prediktivního systému je klíčové pro jeho neustálé zdokonalování a optimalizaci, což přispívá k efektivnějšímu a bezproblémovému chodu celého výrobního toku.

4.1.1 Parametry vyhodnocení prediktivního systému

Celý systém má naučen 169 typů vad, které se mohou v dopravníkovém systému objevit. Tyto vady byly získány z postupného učení modelu a jeho testování. Jelikož se jedná o vady, které mohou způsobit ohrožení produkce či personálu, je žádaná přesnost celého systému pro odhalení vad a následného upozornění pracovníků údržby na 98%.

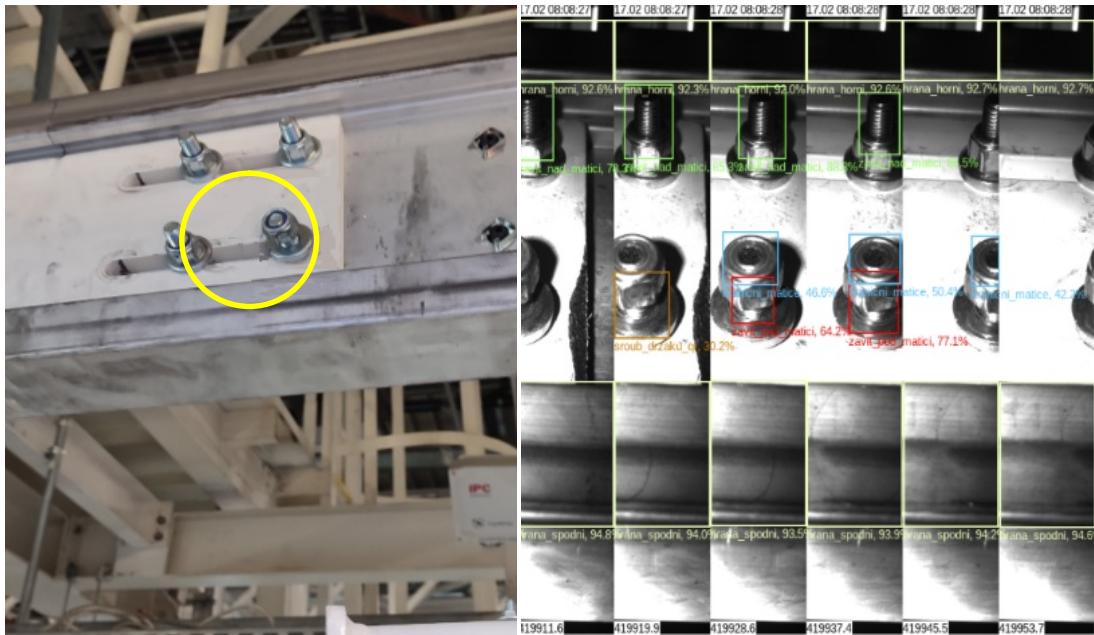
Pro validaci modelu byly zvoleny následující vady, které mají častou frekvenci výskytu:

- Chybějící matice šroubu 2x
- Povolená matice 2x
- Prasklý šroub 1x
- Chybějící šroub 1x
- Cizí předmět v profilu 2x
- Chybějící spony držáku šín 2x

Takto zvolené vady byly simulovány přímo na dopravníku, tak aby nedošlo k ohrožení pracovníků či produkce. Tyto defekty byly náhodně rozmístěny po celé délce dopravníkového toku (na délce necelého kilometru).

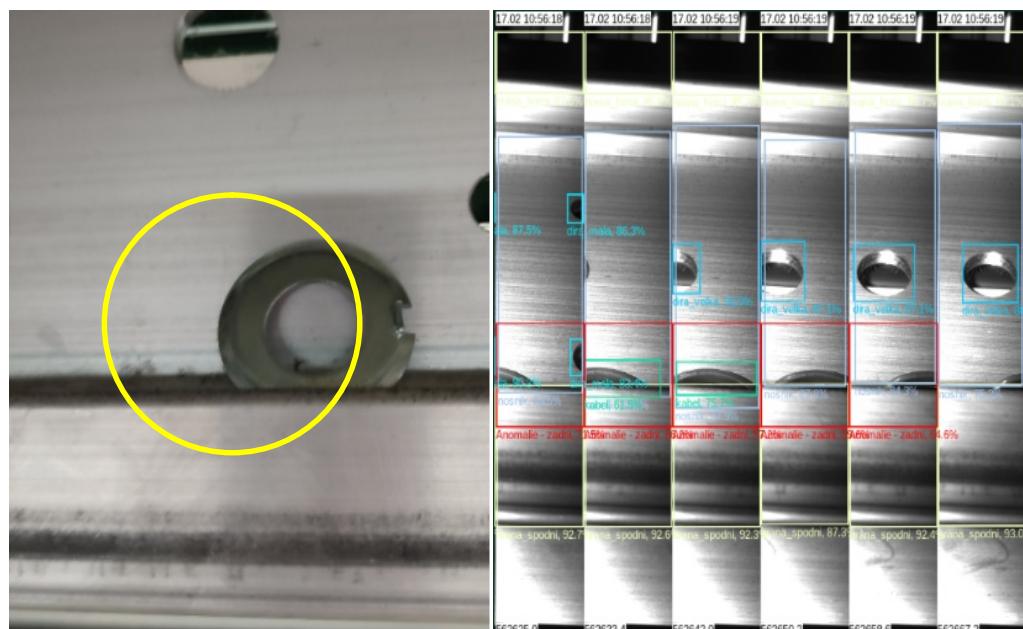
4.1.2 Vyhodnocení simulační zkoušky

Vyhodnocení simulační zkoušky našeho modelu přineslo skvělý výsledek – 100%. Toto potvrzuje vynikající schopnosti našeho modelu v identifikaci specifických anomalií. Během této zkoušky byly úspěšně detekovány všechny simulované vady s výjimečnou přesností. Tato 100% úspěšnost naznačuje vysokou schopnost našeho modelu odhalovat různorodé problémy v konkrétním prostředí. Na obrázku 11 a obrázku 12 můžeme vidět, jak jsme schopni identifikovat povolenou matici či přítomnost cizích předmětů. Toto ukazuje naši připravenost v oblasti prediktivní údržby a prevence potenciálních problémů. Výsledky této simulační zkoušky jsou povzbudivé a poskytují pevný základ pro rozšíření našeho modelu v reálném průmyslovém prostředí. Tato úspěšnost v detekci všech specifikovaných vad podporuje víru v kvalitu a spolehlivost našeho systému pro monitorování a identifikaci anomalií.



Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr. 11 Simulovaný stav a vyhodnocení systému povolené matice šroubu



Zdroj: (Interní materiály Škoda Auto a.s., 2023)

Obr. 12 Simulovaný stav a vyhodnocení systému cizí předmět v profilu

4.2 Budoucí směřování systému prediktivní údržby

Náš projekt, který byl úspěšně implementován v plném rozsahu, ukázal možnou cestu a hlavně výhody využití umělé inteligence v automobilovém průmyslu a preventivní údržbě. Pro budoucí vývoj našeho systému je plánováno rozšíření o

nové funkcionality, stejně jako přenesení našeho systému do okolních výrobních linek. Takovýto krok představuje logický vývoj dalších kroků, nicméně přenesení systému do nových dopravníků přináší nové výzvy a to hlavně v adaptaci na nová specifika daných systémů. To zahrnuje analýzu jejich konstrukce, provozních podmínek a potřeb v oblasti údržby. Stejně tak je nutné provést nové učení algoritmu, jelikož každý dopravník má svá specifika a je budován vždy na základě potřeb, které se mohou lišit.

Již v tuto dobu jsou zpracovány nové projekty pro nasazení našeho systému po dalších výrobních linkách. Implementace takového technologie však není možná okamžitě. V dnešní moderní době nicméně věřím v budování nových systémů na našich základech a jejich stále větší nasazování. Náš projekt postavil solidní základy, na kterých je možné stavět a hlavně prokázal, že umělá inteligence a její možnosti jsou stále větším přínosem pro průmyslové odvětví.

Závěr

V průběhu této bakalářské práce jsme se hlouběji seznámili s dynamikou a výzvami moderní průmyslové výroby, s důrazem na automobilový průmysl, a konkrétně na společnost Škoda Auto. První kapitola nám poskytla obecný výhled do průmyslové výroby, s důrazem na klíčové trendy spojené s průmyslem 4.0, principy výrobního procesu, a plýtvání v různých formách. Následující kapitola se podrobněji zaměřila na montážní linku ve společnosti Škoda Auto, představila její strukturu, klíčové procesy a faktory ovlivňující její efektivitu, včetně závěsného dopravníkového systému a sběru dat z montážní linky.

Třetí kapitola se věnovala optimalizaci stavu prostojů prostřednictvím prediktivní údržby. Zabývali jsme se výběrem technologie pro prevenci defektů závěsného dopravníku, navrhli jsme systém pro preventivní údržbu a zkoumali možnosti zlepšení a maximalizace výkonnosti výrobní linky.

Ve čtvrté a poslední kapitole jsme se soustředili na důkladné vyhodnocení implementovaného systému prediktivní údržby ve společnosti Škoda Auto. Prováděli jsme pečlivou analýzu dosažených výsledků, hodnotili účinnost opatření a přínosy pro celkový výrobní proces. Na závěr jsme podrobně zkoumali parametry vyhodnocení prediktivního systému, analyzovali výsledky simulačních zkoušek a nahlíželi do budoucnosti systému prediktivní údržby ve specifickém prostředí automobilového průmyslu.

Celkově lze konstatovat, že implementace prediktivní údržby ve společnosti Škoda Auto přinesla pozitivní výsledky. Systém nejen úspěšně předpovídá potenciální problémy a minimalizoval prostoj, ale také přinesl efektivní preventivní opatření. Výsledky simulačních zkoušek poskytly další potvrzení schopnosti systému reagovat na různé scénáře a předvídat potenciální výpadky.

Budoucí směřování systému prediktivní údržby ve společnosti Škoda Auto bude zahrnovat další zdokonalení a rozšíření technologií a metodik v souladu s neustále se vyvíjejícím prostředím automobilového průmyslu. Tato bakalářská práce přináší ucelený pohled na význam prediktivní údržby v průmyslovém kontextu, s důrazem na konkrétní aplikace v automobilovém odvětví, a poskytuje základ pro další inovace v oblasti optimalizace výrobních procesů.

Seznam literatury

- ANIRUDH, V.K.
SPICEWORKS. *How Does Artificial Intelligence Learn Through Machine Learning Algorithms?* [online]. 2022 [cit. 2023-11-26]. Dostupné z: <https://www.spiceworks.com/tech/artificial-intelligence/articles/how-does-ai-learn-through-ml-algorithms/>
- BARTODZIEJ, Ch. J. *The Concept Industry 4.0 An Empirical Analysis of Technologies and Applications in Production Logistics.* Berlin, Germany: SpringerGabler, 2017. 150 s. BestMasters. ISBN 978-3-658-16501-7.
- BROWN, Sara. MIT SLOAN SCHOOL OF MANAGEMENT. *Machine learning, explained* [online]. 2021 [cit. 2023-11-26]. Dostupné z: <https://mitsloan.mit.edu/ideas-made-to-matter/machine-learning-explained>
- ECONOMY-PEDIA.COM. *Průmyslová výroba - co to je, definice a pojem* [online]. [cit. 2023-11-25]. Dostupné z: <https://cs.economy-pedia.com/11037357-industrial-production#>
- ESPOSITO, Dino a Francesco ESPOSITO. *Introducing Machine Learning.* PearsonEducation, 2020. ISBN 978-0-13-556566-7.
- Flídr, J. a kol. Propojení výroby a informačních systémů v praxi. Praha: GRADA Publishing, 2023, 288 s. ISBN 978-80-247-2413-3.
- Hendl, J. *Big data Věda o datech - základy a aplikace*, 1st ed.; Grada Publishing, a.s.: Praha, 2021. 221s. ISBN 978-80-271-4478-5
- IBM. *What is deep learning?* [online]. c2023 [cit. 2023-11-26]. Dostupné z: <https://www.ibm.com/topics/deep-learning>
- INFOCUBE S.R.O. *Průmysl* [online]. c2021 [cit. 2023-11-25]. Dostupné z: <https://www.oneindustry.cz/lexikon/prumysl/>
- INSIDER INTELLIGENCE INC. *What is the Internet of Things? What IoT means and how it works* [online]. 2023 [cit. 2023-11-26]. Dostupné z: <https://www.insiderintelligence.com/insights/internet-of-things-definition/>
- Interní materiály Škoda Auto a.s., 2023.

JUROVÁ, M. a kol. Výrobní a logistické procesy v podnikání. Praha: GRADA Publishing, 2016, 256 s. ISBN 978-80-271-9330-1.

KEŘKOVSKÝ, Miloslav – VALSA, Ondřej. *Moderní přístupy k řízení výroby*. 3.doplněné vydání. Praha: C. H. Beck, 2012. 176 s. ISBN 978-80-7179-319-9.

Marr, B. and Ward, M. (2019) Artificial Intelligence in Practice. 1st edn. Wiley. Available at: <https://www.perlego.com/book/991892/artificial-intelligence-in-practice-how-50-successful-companies-used-ai-and-machine-learning-to-solve-problems-pdf>.

MINISTERSTVO PRŮMYSLU A OBCHODU. Iniciativa průmysl 4.0, [online]. MPO, © 2019 [cit. 2023-11-26]. Dostupné z: <https://www.mpo.cz/assets/dokumenty/53723/64358/658713/priloha001.pdf>

ORACLE. *Internet of Things* [online]. 2023 [cit. 2023-11-26]. Dostupné z: <https://www.oracle.com/cz/internet-of-things/what-is-iot/>

SHAIP. *Co je rozpoznávání obrazu AI a jak funguje?* [online]. c2018-2023 [cit. 2023-11-26]. Dostupné z: <https://cs.shaip.com/blog/what-is-ai-image-recognition-and-how-does-it-work/>

SHAW, Greg; ARKAN, Çağlayan. *Thefuturecomputed: AI &manufacturing / by Greg Shaw; foreword by ÇağlayanArkan*. Microsoft, 2019. 135 s. ISBN 9781074042066.

ŠVECOVÁ, Lenka a Jaromír VEBER. *Produkční a provozní management*. Praha: GRADA Publishing, 2021, 344 s. ISBN 978-80-271-4620-8.

TRADE MEDIA INTERNATIONAL. Sedmero smrtelných hřichů v rámci štíhlé výroby. HILL, Kevin. *Vše o průmyslu, portál pro moderní výrobu* [online]. 2018 [cit. 2023-11-26]. Dostupné z: <https://www.vseoprumyslu.cz/inspirace/trendy/sedmero-smrtelnych-hrichu-v-ramci-stihle-vyroby.html>

USTUNDAG, ALP a Emre CEVIKCAN. *Industry 4.0: Managing The Digital Transformation*. Switzerland: SpringerCham, 2017, 286 s. ISBN 978-3-319-57870-5.

VORNE INDUSTRIES INC. OEE (OVERALL EQUIPMENT EFFECTIVENESS) [online]. c2011-2023 [cit. 2023-11-26]. Dostupné z: <https://www.leanproduction.com/oee/>

Seznam obrázků a tabulek

Seznam obrázků

Obr. 1 - Grafické znázornění OEE.....	14
Obr.2Cizí předmět v hliníkovém profilu	28
Obr.3Opotřebení dráhy – rýha v hliníkovém profilu	28
Obr.4Špatně nastavená dilatace spáry mezi profily	29
Obr.5Rozsáhlé praskliny hliníkového profilu	29
Obr. 6Špona v šínovém systému	30
Obr.7Opotřebení šínového systému.....	30
Obr.8 Cizí předmět v šínovém systému	31
Obr. 9 Princip strojového učení	34
Obr. 10 Blokové schéma učení prediktivního systému	35
Obr.11Simulovaný stav a vyhodnocení systému povolené matice šroubu.....	38
Obr. 12Simulovaný stav a vyhodnocení systému cizí předmět v profilu.....	38

Seznam tabulek

Tab. 1 - Sedm druhů ztrát	10
Tab. 2 – Přehled využitelnosti linky	25
Tab. 3 – přehled prostojů linky za uplynulé směny.....	25

ANOTAČNÍ ZÁZNAM

AUTOR	Fidler Ondřej		
STUDIJNÍ PROGRAM/OBOR/SPECIALIZACE	Logistika a management kvality		
NÁZEV PRÁCE	Využití nástrojů umělé inteligence pro predikci prostojů ve výrobních procesech v automobilovém průmyslu		
VEDOUCÍ PRÁCE	Ing. Tomáš Malčic, Ph.D.		
KATEDRA	KRVLK - Katedra řízení výroby, logistiky a kvality	ROK ODEVZDÁNÍ	2023
POČET STRAN	45		
POČET OBRÁZKŮ	12		
POČET TABULEK	3		
POČET PŘÍLOH	0		
STRUČNÝ POPIS	<p>Tato práce zkoumá implementaci prediktivní údržby ve společnosti Škoda Auto s cílem optimalizovat výrobní proces. Cílem je navrhnut systém umělé inteligence pro předpověď a minimalizaci prostojů na montážní lince. Rešení zahrnuje analýzu stavu linky, výběr technologií pro prevenci defektů a implementaci prediktivního údržbového systému.</p> <p>Implementace vedla k efektivnímu snížení prostojů a účinnému provedení preventivních opatření. Zjištění této práce naznačují, že umělá inteligence a prediktivní údržba v automobilovém průmyslu zásadně přispívají k efektivitě a minimalizaci rizik výrobních procesů.</p> <p>Práce konstatuje, že tato implementace představuje klíčový krok směrem k efektivnějšímu průmyslovému prostředí ve společnosti Škoda Auto.</p>		
KLÍČOVÁ SLOVA	Prediktivní údržba, automobilový průmysl, umělá inteligence, výrobní proces, montážní linka, Škoda Auto, prostoj, efektivita, technologie 4.0, prevence defektů.		

ANNOTATION

AUTHOR	Fidler Ondřej		
FIELD	Logistics and Quality Management		
THESIS TITLE	Utilization of Artificial Intelligence Tools for Predicting Downtime in Manufacturing Processes in the Automotive Industry		
SUPERVISOR	Ing. Tomáš Malčík, Ph.D.		
DEPARTMENT	KRVLK - Department of Production, Logistics and Quality Management	YEAR	2023
NUMBER OF PAGES	45		
NUMBER OF PICTURES	12		
NUMBER OF TABLES	3		
NUMBER OF APPENDICES	0		
SUMMARY	<p>This thesis explores the implementation of predictive maintenance at Škoda Auto to optimize the manufacturing process. The objective is to design an artificial intelligence system for predicting and minimizing downtime on the assembly line. The solution involves analyzing the line's current state, selecting technologies for defect prevention, and implementing a predictive maintenance system.</p> <p>The implementation has resulted in an effective reduction of downtime and successful execution of preventive measures. Findings from this study suggest that artificial intelligence and predictive maintenance significantly contribute to the efficiency and risk reduction in manufacturing processes within the automotive industry.</p> <p>The thesis concludes that this implementation represents a pivotal step toward a more efficient industrial environment at Škoda Auto.</p>		
KEY WORDS	Predictive maintenance, automotive industry, artificial intelligence, manufacturing process, assembly line, Škoda Auto, downtime, efficiency, Industry 4.0 technology, defect prevention.		