

Analýza využití umělé inteligence v oblasti kontroly kvality výrobní společnosti

Lukáš Julina

Bakalářská práce
2024



Univerzita Tomáše Bati ve Zlíně
Fakulta managementu a ekonomiky

Univerzita Tomáše Bati ve Zlíně
Fakulta managementu a ekonomiky
Ústav průmyslového inženýrství a informačních systémů

Akademický rok: 2023/2024

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: Lukáš Julina
Osobní číslo: M210441
Studijní program: B0413P050013 Průmyslové inženýrství
Forma studia: Prezenční
Téma práce: Analýza využití umělé inteligence v oblasti kontroly kvality výrobní společnosti

Zásady pro vypracování

Úvod

Definujte cíle práce a použité metody zpracování práce.

I. Teoretická část

- Vypracujte literární rešerši z oblasti umělé inteligence a jejího využití ve výrobní společnosti.

II. Praktická část

- Popište a analyzujte současný stav kontroly kvality ve vybrané společnosti.
- Na základě analýzy navrhněte řešení vedoucí k zavedení AI v oblasti kontroly kvality v dané výrobní firmě.
- Zhodnotte přínosy navrhovaného řešení.

Závěr

Rozsah bakalářské práce: **cca 40 stran**
Forma zpracování bakalářské práce: **tištěná/elektronická**

Seznam doporučené literatury:

KAPLAN, Jerry. *Artificial Intelligence: What Everyone Needs to Know*. New York: Oxford University Press, 2016. ISBN 978-0-19-060239-0.
RUSSELL, Stuart J. a NORVIG, Peter. *Artificial Intelligence: a Modern Approach*. Third edition. Boston: Pearson, 2016. ISBN 978-1-292-15396-4.
SZELESKI, Richard. *Computer Vision: Algorithms and Applications*. Second edition. Cham: Springer, 2022. ISBN 978-3-030-34371-2.

Vedoucí bakalářské práce: **Ing. Eva Juříčková, Ph.D.**
Ústav průmyslového inženýrství a informačních systémů

Datum zadání bakalářské práce: **5. února 2024**
Termín odevzdání bakalářské práce: **17. května 2024**

L.S.

prof. Ing. David Tuček, Ph.D.
děkan

prof. Ing. Felicitá Chromjaková, Ph.D.
garant studijního programu

Ve Zlíně dne 5. února 2024

PROHLÁŠENÍ AUTORA BAKALÁŘSKÉ PRÁCE

Prohlašuji, že

- beru na vědomí, že odevzdáním bakalářské práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb. o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších právních předpisů, bez ohledu na výsledek obhajoby;
- beru na vědomí, že bakalářská práce bude uložena v elektronické podobě v univerzitním informačním systému dostupná k prezenčnímu nahlédnutí, že jeden výtisk bakalářské práce bude uložen na elektronickém nosiči v příruční knihovně Fakulty managementu a ekonomiky Univerzity Tomáše Bati ve Zlíně;
- byl/a jsem seznámen/a s tím, že na moji bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- beru na vědomí, že podle § 60 odst. 1 autorského zákona má UTB ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- beru na vědomí, že podle § 60 odst. 2 a 3 autorského zákona mohu užít své dílo – bakalářskou práci nebo poskytnout licenci k jejímu využití jen přípouští-li tak licenční smlouva uzavřená mezi mnou a Univerzitou Tomáše Bati ve Zlíně s tím, že vyrovnání případného přiměřeného příspěvku na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše) bude rovněž předmětem této licenční smlouvy;
- beru na vědomí, že pokud bylo k vypracování bakalářské práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tedy pouze k nekomerčnímu využití), nelze výsledky bakalářské práce využít ke komerčním účelům;
- beru na vědomí, že pokud je výstupem bakalářské práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá. Neodevzdání této součásti může být důvodem k neobhájení práce.

Prohlašuji,

1. že jsem na bakalářské práci pracoval samostatně a použitou literaturu jsem citoval. V případě publikace výsledků budu uveden jako spoluautor.
2. že odevzdaná verze bakalářské práce a verze elektronická nahraná do IS/STAG jsou totožné.

Ve Zlíně

Jméno a příjmení: Lukáš Julina

.....
podpis diplomanta

ABSTRAKT

Tahle bakalářská práce se zabývá problematikou zefektivnění současné finální kontroly kvality ve vybrané společnosti pomocí implementace umělé inteligence. Teoretická část vysvětluje základní pojmy z oblasti kvality, umělé inteligence a následné propojení umělé inteligence a kontroly kvality.

Praktická část v úvodu představuje vybranou společnost. Následně je praktická část zaměřena na analýzu současného stavu kontroly kvality. Poté následuje samotný návrh implementace umělé inteligence do oblasti kontroly kvality včetně ekonomického zhodnocení a na závěr jsou uvedeny přínosy tohoto řešení.

Klíčová slova: kvalita, kontrola kvality, umělá inteligence

ABSTRACT

This bachelor thesis addresses the issue of improving the current final quality control in a selected company through the implementation of artificial intelligence. The theoretical part explains basic concepts in the field of quality, artificial intelligence, and the subsequent integration of artificial intelligence with quality control.

The practical part initially introduces the selected company. It then focuses on analyzing the current state of quality control. This is followed by the actual proposal for implementing artificial intelligence into the area of quality control, including an economic evaluation, and concludes with the benefits of this solution.

Keywords: quality, quality control, artificial intelligence

Na tomto místě bych rád poděkoval vedoucí mé bakalářské práce Ing. Evě Juříčkové, Ph.D. za odborné vedení a pevné nervy v průběhu zpracovávání bakalářské práce.

Dále bych rád poděkoval celé společnosti AGD PRINT s.r.o. za možnost zpracovávat bakalářskou práci ve firmě a celému vedení firmy za užitečné rady, kvalitní spolupráci a poskytnutí potřebných informací.

Prohlašuji, že odevzdaná verze bakalářské práce a verze elektronická nahraná do IS/STAG jsou totožné.

OBSAH

ÚVOD	9
CÍLE A METODY ZPRACOVÁNÍ PRÁCE	10
I TEORETICKÁ ČÁST	11
1 VÝZNAM KVALITY	12
1.1 VÝZNAM KVALITY V KONTEXTU KAIZEN GEMBA	12
1.2 VÝZNAM KVALITY V METODĚ SIX SIGMA A LEAN SIX SIGMA.....	13
1.3 KONTROLA KVALITY	13
2 UMĚLÁ INTELIGENCE	15
2.1 CO JE TO UMĚLÁ INTELIGENCE?.....	15
2.2 KOMPONENTY UMĚLÉ INTELIGENCE	15
2.3 PŘÍKLADY VYUŽITÍ UMĚLÉ INTELIGENCE VE FIRMÁCH	16
2.4 VÝZNAM UMĚLÉ INTELIGENCE VE VÝROBNÍ SPOLEČNOSTI	18
2.5 PREDIKTIVNÍ ÚDRŽBA ZAŘÍZENÍ	19
2.5.1 Klíčové součásti prediktivní údržby založené na umělé inteligenci	19
3 KONTROLA KVALITY A JEJÍ SPOJENÍ S UMĚLOU INTELIGENCÍ	21
3.1 KONTROLA KVALITY	21
3.2 CHYTRÁ KONTROLA KVALITY A JEJÍ FÁZE	21
4 OBLASTI UMĚLÉ INTELIGENCE NEURAL NETWORKS, COMPUTER VISION, MACHINE LEARNING A DEEP LEARNING	23
4.1 NEURAL NETWORKS (NEURONOVÉ SÍTĚ)	23
4.2 COMPUTER VISION (POČÍTAČOVÉ VIDĚNÍ)	24
4.3 DEEP LEARNING (HLUBOKÉ UČENÍ)	24
4.4 MACHINE LEARNING (STROJOVÉ UČENÍ).....	25
5 BUDOUCNOST UMĚLÉ INTELIGENCE VE VÝROBNÍCH SPOLEČNOSTECH	27
II PRAKTICKÁ ČÁST	29
6 PŘEDSTAVENÍ SPOLEČNOSTI	30
6.1 ZÁKLADNÍ ÚDAJE SPOLEČNOSTI	30
6.3 HISTORIE SPOLEČNOSTI.....	31
6.4 NABÍZENÉ PRODUKTY A SLUŽBY	32
7 ANALÝZA OBECNÉHO PROSTŘEDÍ POMOCÍ SWOT ANALÝZY	34
7.1.1 Silné stránky.....	34
7.1.2 Slabé stránky	34
7.1.3 Příležitosti.....	35

7.1.4	Hrozby	35
8	ANALÝZA SOUČASNÉHO STAVU KONTROLY KVALITY	38
8.1	PŘEDVÝROBNÍ FÁZE KONTROLY KVALITY	38
8.1.1	Kontrola grafiky a textu	38
8.1.2	Výběr materiálů	39
8.2	PRŮBĚŽNÁ KONTROLA KVALITY	39
8.3	KONTROLA FINÁLNÍHO VÝROBKU	40
8.4	ANALÝZA FINÁLNÍ KONTROLY KVALITY ŠTÍTKU XYZ	43
9	NÁVRH ŘEŠENÍ VEDOUcí K ZAVEDENí AI V OBLASTI KONTROLY KVALITY	45
9.1	DATABÁZE DEFEKTŮ	46
9.2	SOFTWAREVÁ ČÁST NÁVRHU	48
9.2.1	Představení OpenCV	48
9.2.2	Využití OpenCV v návrhu	48
9.2.3	Představení vývojové platformy PyTorch	49
9.2.4	Představení vývojové platformy TensorFlow	50
9.2.5	Porovnání platforem PyTorch a TensorFlow	50
9.3	HARDWAROVÁ ČÁST NÁVRHU	51
9.3.1	Počítač	51
9.3.2	Kamera a osvětlení	52
10	EKONOMICKÉ ZHODNOCENí A RIZIKA NÁVRHU	54
10.1	RIZIKA NÁVRHU	56
11	PŘÍNOSY PRÁCE	57
11.1	ČASOVÁ ÚSPORA	57
11.2	KVALITA VÝROBKŮ	57
	ZÁVĚR	58
	SEZNAM POUŽITÉ LITERATURY	59
	SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK	61
	SEZNAM OBRÁZKŮ	62
	SEZNAM TABULEK	63
	SEZNAM PŘÍLOH	64

ÚVOD

Umělá inteligence (AI) je charakterizována jako soubor funkcí, které jsou vytvářeny umělými systémy. Tyto systémy mají schopnost neustále se učit, porozumět informacím a samostatně přemýšlet. Na základě vývoje můžeme umělou inteligenci kategorizovat do různých fází, od základních reaktivních systémů po ty, které se samy učí a používají získané znalosti pro budoucí rozhodování. Například autonomní roboti využívají tuto schopnost se učit, zatímco rozvinutější formy AI by mohly dokonce pochopit lidské emoce nebo mít sebeuvědomění, což je ale v současné chvíli mimo dosah.

Význam umělé inteligence stále roste, protože její schopnosti se neustále rozvíjejí, což umožňuje lidem zefektivnit řadu činností. Umělá inteligence pomáhá firmám zlepšovat svou komunikaci se zákazníky a optimalizovat výrobní i obchodní procesy. Její uplatnění nalezneme v mnoha sektorech, včetně finančních služeb pro řízení rizik, personalizace nabídek zboží či v průmyslu pro vývoj autonomních vozidel. Umělá inteligence také pomáhá ve zdravotnictví a zvyšuje tak šance na záchranu lidského života tím, že umožňuje vyvíjet systémy na jejím základu, které pak umožňují rychlejší detekci nemocí. Se stále větším rozvojem AI se také zvětšují obavy zaměstnanců o ztrátu pracovních míst, které by mohly být nahrazeny automatizovanými systémy. Avšak samotná implementace umělé inteligence také otevírá dveře k novým pracovním příležitostem a vyžaduje od pracovníků adaptaci a celoživotní vzdělávání.

V oblasti kontroly kvality AI přináší revoluci zejména spojením nástrojů pro zpracování obrazu a následné vyhodnocování modely umělé inteligence, strojového a hlubokého učení. Tato kombinace umožňuje vytvářet vysoce efektivní automatické kontrolní systémy, které pomáhají identifikovat defekty a pomáhají dodržování standardů kvality s vysokou přesností a minimalizací lidské chyby.

Cílem mé práce je vytvořit návrh implementace umělé inteligence v oblasti kontroly kvality a tím ušetřit čas při finální kontrole kvality.

Práce je rozdělena na dvě části, a to teoretickou a praktickou. V teoretické části bude vysvětlena kvalita, umělá inteligence a její spojení s kontrolou kvality a budou vysvětleny pokročilé oblasti umělé inteligence. Praktická část práce se zaměřuje na samotný návrh implementace umělé inteligence ve společnosti AGD PRINT s.r.o.

CÍLE A METODY ZPRACOVÁNÍ PRÁCE

Hlavním cílem bakalářské práce je dosažení časové úspory při finální kontrole kvality výrobků pomocí umělé inteligence. Jedním z prostředků, jak dosáhnout implementace umělé inteligence do kontroly kvality je spojení nástrojů OpenCV, aby mohl počítač „vidět“, a nástroje PyTorch, který bude vstupní data vyhodnocovat. Mezi důležité cíle také patří dodržení stávající úrovně kvality a její případné zlepšení.

Teoretická část této práce bude zhotovena pomocí literární rešerše z oblasti kvality, umělé inteligence a jejich propojením. Při zpracování teoretické části bylo využito knih, odborných článků a internetových zdrojů. Bylo čerpáno z českých, ale i cizojazyčných zdrojů, které byly využity z větší části, neboť toto téma se ve větším rozsahu řeší v zahraničí.

Praktická část se pak zaměřuje na představení vybrané společnosti a analýzu současného stavu. Následně v hlavní části práce bude navrženo samotné řešení pro implementaci umělé inteligence včetně popsání jednotlivých částí návrhu.

Použité metody:

Byla vypracována SWOT analýza na společnost, která se zabývá silnými a slabými stránkami spolu s příležitostmi a hrozbami, které mohou ovlivnit společnost.

Analýza současného stavu kontroly kvality probíhala způsobem pozorování a získávání informací od pracovníků, co dělají za kontrolu kvality na všech pracovištích ve vybrané společnosti za účelem odhalení nejvhodnějšího místa pro implementaci návrhu.

Analýza finální kontroly kvality probíhala měřením času jednotlivých kroků kontroly snímané zakázky.

I. TEORETICKÁ ČÁST

1 VÝZNAM KVALITY

Podle Suchánka (2011) kvalita může být definována, jako stupeň splnění požadavků souborem inherentních znaků. Kvalitou produktu je tedy myšlena nejen technická vyspělost (ve smyslu technologie výroby eventuálně způsobu a úrovně poskytnutí služby a technické vyspělosti nebo sofistikovanosti produktu), ale zejména schopnost uspokojit požadavky zákazníků. Přitom platí, že čím více je produkt v souladu s požadavky zákazníka, tím je kvalitnější.

Kvalita výrobků a služeb je provázena výdaji, které lze rozdělit do dvou skupin, a to na fixní výdaje a výdaje variabilní. Existuje jistá úroveň těchto, kdy již není možné dále snižovat náklady, aniž byste zlepšili kvalitu, zkrátili výrobní cyklus nebo zvýšili účinnost procesu. Tyto náklady jsou nutné pro udržení životaschopnosti firmy. (Imler, 2008)

Podle Imaie (2005) se pod kvalitou rozumí kvalita výrobků a služeb. Nicméně v širším smyslu to rovněž znamená kvalitu procesů a práce v pozadí těchto výrobků a služeb. To první můžeme nazývat kvalitou výsledku, a to druhé kvalitou procesu. Podle této definice se kvalita týká všech fází podnikové činnosti. Konkrétně procesu vývoje, projekce, výroby, prodeje a údržby výrobků a služeb.

V rámci vymezení pojmu kvalita, je však nezbytné poznamenat, že neexistuje jediná správná definice toho, co to kvalita vlastně je. (Suchánek, 2011)

1.1 Význam kvality v kontextu Kaizen Gemba

Gemba se na otázky kvality dívá z jiného úhlu než management proti proudu. Zatímco ten vyžaduje sofistikované nástroje (revize projektu, provádění experimentů, hodnota analýz, hodnotové inženýrství a různé nástroje QFD (Quality Function Deployment)), mnoho problémů na pracovišti se týká jednoduchých záležitostí, jako je úroveň řemeslné práce a zvládání každodenních obtíží a nepravidelností, například nevhodné pracovní standardy či nedbalostní chyby personálu. (Imai, 2005)

Imai (2005) píše: Nejen že je možné zlepšit kvalitu a zároveň snížit náklady, my jednoduše musíme udělat oboje, abychom obstáli tváří v tvář rostoucím zákaznickým požadavkům. Podívejme se kupříkladu na konkurenci na trhu s luxusními automobily. Předpokládejme, že jeden výrobce se bude držet tradičního přístupu, podle něhož stojí vyšší kvalita více peněz. Hlavním způsobem, jak zajistit kvalitu, je pro tohoto výrobce nákup dražších výrobních strojů a testovacích zařízení a najímání více lidí pro jejich obsluhu. Produkty

tohoto výrobce mají pověst světové kvality, ale jejich cena je velmi vysoká. Předpokládejme, že se na trhu objeví nový konkurent, jenž má za to, že vyšší kvalita a nižší náklady jsou kompatibilní a dokázal vytvořit automobil stejné nebo vyšší kvality než předchozí výrobce, ale za nižší cenu. Jak bude první výrobce na novou situaci reagovat? To je skutečná povaha zjevného nebezpečí, jemuž dnes čelí společnosti, které vyznávají zastaralý princip, že kvalita stojí peníze.

1.2 Význam kvality v metodě Six Sigma a Lean Six Sigma

Six Sigma na rozdíl od svého předchůdce TQM nepovažuje míru vyhovění interním požadavkům za to, co definuje kvalitu. Kvalita v pojetí Six Sigma představuje podnikatelský motor pro zvýšení profitability podniku tím, že se soustředí na zvýšení hodnoty dodávané zákazníkům a na celkovou efektivitu procesů. Má tedy dvě roviny hodnocení, a to „potencionální kvalitu“, tedy to, čeho lze v oblasti kvality danými prostředky dosáhnout a „skutečnou kvalitu“, tedy to, čeho proces reálně dosahuje. (Svozilová, 2011)

Lean Six Sigma je metoda přinášející nástroje, které mají za úkol pomoci managementu zlepšit kvalitu a celkový výkon výrobního procesu. Tato metoda vznikla kombinací dvou podružných přístupů. První přístupem je Lean management, jehož hlavní úlohou je snížit plýtvání a urychlit tak průběh celého procesu a s ním spojené náklady. Časem však výroba došla do bodu, kdy ke zlepšování výrobního procesu nestačilo pouze urychlení a odstranění plýtvání a začalo se tak přemýšlet, jak dosáhnout ještě větší efektivity. Zásadou se najednou stala kvalita výrobků. Už nebyla prioritou pouze vyrábět rychle a levně, ale přidala se také snaha snížit defekty ve výrobě a zvýšit tím kvalitu celého procesu. Došlo tak ke sloučení Lean metody s metodou Six Sigma, která je primárně zaměřená na statistické vyhodnocování zmetkovitosti výroby a kvalitu procesu. (Svozilová, 2011)

1.3 Kontrola kvality

Podle Svozilové (2016) Účelem kontroly kvality je nalezení chyb vzniklých při realizaci v již vytvořených produktech před předáním zákazníkovi. V případě nalezení chyb musí projektový manažer a projektový tým udělat co nejrychleji opatření, které povedou k jejich odstranění.

K dosažení požadované kvality je nutné vynaložit náklady. Ty lze definovat, jako veškeré spotřebované zdroje na dosažení zákazníkem požadované kvality produktu v peněžním vyjádření. Vytvoření kvalitního produktu je pro projekt klíčové. Proto je nutné nesnižovat

náklady na úkor kvality. V případě snižování nákladů mohou vznikat problémy, které zapříčiní vznik dalších nákladů a ty bývají vyšší než samotné náklady na prevenci proti nim. Podle odhadů bývají průměrné náklady na kvalitu v projektu zhruba 3-5 % z celkové ceny. Nicméně záleží také na dalších faktorech jako rozsah projektu, zkušenosti s obdobnými projekty apod. (Svozilová, 2016)

Svozilová (2016) dělí náklady do pěti kategorií:

- Náklady na prevenci jako jsou školení, průzkumy pro výběr dodavatelů apod.
- Náklady na hodnocení kvality, kde patří náklady na měření, kontrolu a testování produktů, ověření technických návrhů a designu, průběžné kontroly.
- Interní náklady na odstranění vad zde udává například opravy a zmetky, náklady na držení skladů, náklady na předčasně ukončené produkce, dokumentace oprav.
- Externí náklady na odstranění vad jako jsou náklady na záruky, vyřizování stížností, ztráta budoucích obchodních příležitostí.
- Měření a testovací vybavení

2 UMĚLÁ INTELIGENCE

Kapitola zahrnuje základní vysvětlení pojmu umělá inteligence, které je důležité pro čtenáře pro pochopení následných souvislostí.

2.1 Co je to umělá inteligence?

Je to lehká otázka na položení ale těžká na zodpovězení, z dvou důvodů. Zaprvé, existuje malá shoda ohledně toho, co inteligence je. Zadruhé, není moc důvodů věřit, že inteligence strojů má zatím mnoho společného s lidskou inteligencí. (Kaplan, 2016)

Umělá inteligence je dnes nejmocnější technologií dostupnou lidstvu a největším omylem, kterého se může kdokoli dopustit, je ji ignorovat. Vůdci národů i podniků si uvědomují, jak obrovský potenciál příležitostí, které AI přináší, tak i rizika zůstat pozadu v horečce za umělou inteligencí. (Marr, Ward, 2019)

Existuje mnoho navrhovaných definic umělé inteligence (AI), z nichž každá má svůj vlastní úhel pohledu, ale většina se přibližně shoduje na konceptu vytváření počítačových programů nebo strojů schopných chování, které bychom považovali za inteligentní, pokud by je projevovali lidé. John McCarthy, zakladatel tohoto oboru, popsal tento proces v roce 1955 jako „zajištění, aby stroj jednal způsoby, které by byly nazývány inteligentními, kdyby se tak choval člověk.“ (Kaplan, 2016)

Bylo navrženo mnoho definic AI různými vědci a výzkumníky, například:

Umělá inteligence je studium toho, jak donutit počítače dělat věci, ve kterých jsou v daném okamžiku lidé lepší.

Umělá inteligence je součást počítačových věd, které se zabývají navrhováním inteligentních počítačových systémů, to jsou systémy, které vykazují charakteristiky, které připisujeme inteligenci v lidském chování. (Gupta, Mangla, 2020)

2.2 Komponenty umělé inteligence

Systém umělé inteligence, jak jej popisují autoři Russel, Norvig (2016) ve své knize „Artificial Intelligence: A Modern Approach“, je složitý a vyžaduje několik klíčových komponent pro jeho správné fungování.

Podle těchto autorů je systém AI tvořen pěti základními komponenty (Russel, Norvig, 2016):

Řešení problémů (problem-solving): Tato složka umožňuje systému definovat problém, provést jeho analýzu, vybrat z možných řešení to nejlepší a poté toto řešení aplikovat.

Uvažování (reasoning): Schopnost uvažování znamená, že systém je schopen na základě dostupných informací a znalostí vyvozovat logické závěry a předpovědi, které jsou relevantní pro danou situaci.

Plánování (planning): Tato komponenta je klíčová v situacích, kdy je od systému vyžadováno, aby jeho akce probíhaly ve specifickém pořadí. Systém by měl být schopen efektivně naplánovat své kroky.

Učení (learning): Učení v kontextu AI znamená že systém nejen reaguje na přímé podněty, ale také se vyvíjí a zlepšuje se, čímž rozšiřuje své schopnosti pro budoucí výkony.

Komunikace a chování (communicating and acting): Na rozdíl od předchozích vnitřních složek, komunikace a chování jsou vnějšími projevy. Tyto složky umožňují systému interagovat se světem, například prostřednictvím zraku, sluchu.

2.3 Příklady využití umělé inteligence ve firmách

Existují tři klíčové případy použití AI v podnikání, které se mohou do jisté míry překrývat, ale pomáhají segmentovat příležitosti. Umělá inteligence může pomoci firmám lépe pochopit, kdo jsou jejich zákazníci, předpovídat, které produkty nebo služby budou zákazníci pravděpodobně chtít, předpovídat tržní trendy a poptávku a poskytovat zákazníkům personalizovanější interakce. AI může pomoci firmám vytvářet inteligentnější produkty a služby pro jejich zákazníky. Zákazníci chtějí inteligentnější produkty, jako jsou chytrější telefony, chytrější automobily a chytrější domácí zařízení. (Marr, Ward, 2019)

Ve své knize „Artificial intelligence in practice: How 50 successful companies used artificial intelligence to solve problems“ autoři ukazují na firmy v pěti různých odvětvích bude popsána jedna firma z každého odvětví (Marr, Ward, 2019):

Artificial Intelligence Trailblazers (Průkopníci umělé inteligence) – Microsoft

Cílem Microsoftu je poskytnout firmám nástroje, které mohou využít k implementaci AI ve svých organizacích. Na základní úrovni to může znamenat využití AI nástrojů obsažených v Office 365. PowerPoint je schopen nabízet tipy pro design na základě pozorování práce

uživatelé a Word používá AI k navrhování významů, alternativních frází a ke kontrole pravopisu, gramatiky a interpunkce. Funkce nazvaná „Acronyms“ dokonce pomáhá dešifrovat obtěžující zkratky a zkrácené formy, které se mohou v organizaci nahromadit. Azure Cognitive Services nabízí „předpřipravená“ řešení strojového učení pro rozpoznávání řeči, analýzu textu, počítačové vidění a překlad jazyků. Ide je, že kdokoli, kdo má nápad, jak by firma mohla využít AI k získání hodnoty z jejích dat, může začít, aniž by musel být expertem na AI.

Beverage Companies (Společnosti vyrábějící nápoje) -Starbucks

Starbucks sbírá data o chování svých zákazníků sledováním (s jejich svolením) prostřednictvím svých věrnostních programů a mobilní aplikací. Tyto informace jsou korelovány s dalšími interními a externími daty, včetně meteorologických dat, lokálních dat a firemních dat, jako jsou úrovně zásob, aby Starbucks lépe pochopil, co pohání prodeje. To znamená, že mohou být nabízeny personalizované akce – nabídky zboží, o které má každá zákazník pravděpodobně zájem, přímo jim. Systém s umělou inteligencí, který Starbucks k tomu všemu využívá, se nazývá Digital Flywheel Program. Jeho úkolem je brát v úvahu každý faktor lokality, přes dobu dne, až po počasí – aby předpověděl, co si zákazníci objednájí, když vejdou do dveří nebo si načtou aplikaci na telefonu.

Entertainment Companies (Zábavní společnosti) – Instagram

Instagram zavedl algoritmy umělé inteligence pro filtrování komentářů, které prověřují všechny komentáře nahrávané na síť. Text, stejně jako řeč ve videích, je filtrem analyzován a vše, co je určeno jako urážlivý komentář jako jsou například urážky vzhledu, rasy nebo pohlaví osoby je automaticky filtrováno. Když jsou určité účty často filtrovány, vyvolá to manuální kontrolu ze strany lidského personálu sociální sítě, který rozhodne za uživatele porušuje podmínky služby.

Services Companies (Společnosti nabízející služby) – Hopper

Hopper efektivně nahrazuje tradičního lidského cestovního agenta umělou inteligencí v roli cestovního agenta. Uživatelé sdělí aplikaci svůj cíl cesty a přibližné datum, načež Hopper vyhledá nejlepší dostupné ceny. Čím flexibilnější je uživatel, co se týče data nebo destinace, tím širší škálu letů Hopper prohledá a tím větší je šance na nalezení výhodné nabídky. Na první pohled se Hopper může zdát podobný konvenčním cenovým srovnávacím stránkám, ale jeho odlišnost spočívá v tom, že uživateli také poskytne předpověď. Bude informován, zda

je cena nejlepší, jakou může získat, nebo zda by mu mohlo prospět počkat na lepší nabídku v budoucnosti.

Automotive Companies (Automobilové společnosti) – Tesla

Při využívání autonomních vozidel je umělá inteligence používána k rozhodování na základě podmínek na silnici kolem vozidla, jako je směr jízdy, plánovaný cíl a chování okolního provozu. Data z kamer jsou zpracovávána pomocí technologie počítačového vidění, aby auto mohlo rozumět tomu, co „vidí“ a reagovat podle toho. Tento proces funguje na třech úrovních a to interní (informace shromážděné a zpracované vozidlem), globální (informace shromážděné napříč flotilou autonomních vozidel a sdílené mezi nimi) a lokální (informace shromážděné „ad hoc“ sítěmi autonomních vozidel, která jsou v těsné blízkosti jeden k druhému). Jakmile budou autonomní vozidla běžná, je pravděpodobné, že to bude doplněno daty ze sítí vytvořených mezi jinými stroji jako jsou dopravní kamery, senzory na silnicích, a dokonce mobilní telefony chodců.

2.4 Význam umělé inteligence ve výrobní společnosti

Umělá inteligence (AI) se ukazuje jako klíčový prvek pro zvyšování produktivity a efektivity ve výrobních společnostech. AI umožňuje výrobcům dosahovat významného finančního dopadu prostřednictvím několika klíčových oblastí, jako je prediktivní údržba, zlepšení kvality výrobků, snížení množství odpadu, optimalizace výrobních kapacit a předpovídání poptávky a správy zásob. Tato opatření vedou k významným úsporám nákladů a zvyšují konkurenceschopnost výrobních společností. (Rapp, 2022)

AI umožňuje výrobním společnostem lépe analyzovat a optimalizovat výrobní procesy. Systémy AI mohou identifikovat neefektivní aspekty operací a navrhnout změny, které zlepšují celkovou efektivitu a snižují provozní náklady. Tato schopnost je podpořena pokročilými analytickými nástroji, které zpracovávají velké množství výrobních dat a umožňují přesnější monitorování a úpravy procesů v reálném čase. (Arinez et al., 2020)

AI také zásadně transformuje procesy řízení dodavatelského řetězce, což zahrnuje optimalizaci inventáře, zlepšení předpovídání poptávky a zjednodušení logistiky. Použití robotiky a automatizace na montážních linkách, podporované AI, zvyšuje přesnost a rychlost, přičemž se přizpůsobuje měnícím se výrobním požadavkům. (Srivastava, 2024)

2.5 Prediktivní údržba zařízení

Jednou z nejvýznamnějších aplikací AI v oblasti výroby je prediktivní údržba, která pomáhá předcházet poruchám a výpadkům zařízení. AI systémy analyzují data získaná z výrobních strojů a zařízení, aby předpověděly možné závady dříve, než dojde k jejich skutečnému výskytu. Tímto způsobem mohou společnosti plánovat údržbu efektivněji a minimalizovat nepředvídané provozní přerušení, což vede k vyšší produktivitě a nižším nákladům. (Rapp, 2022)

Prediktivní údržba (PdM) umožňuje identifikovat potenciální problémy dříve, než dojde k poruše, což minimalizuje nepředvídané prostoje a zlepšuje celkovou spolehlivost zařízení. Tento přístup je založen na kontinuálním sběru a analýze dat z různých senzorů a zařízení. (Ucar et al., 2024)

2.5.1 Klíčové součásti prediktivní údržby založené na umělé inteligenci

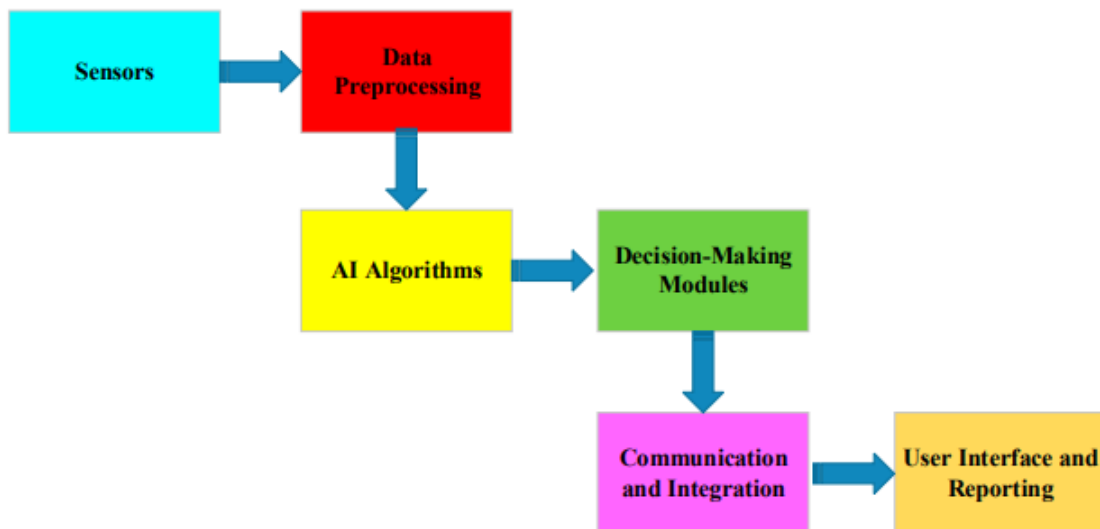
Prediktivní údržba založená na umělé inteligenci (AI-based PdM), se podle Ucara et al. (2024) dá rozdělit do šesti základních komponent:

- **Senzory (sensors):** Jsou základními sběrači dat v systému PdM. Tyto specializované zařízení jsou strategicky umístěny na vybaveních a strojích, aby neustále monitorovaly různé parametry, jako jsou teplota, tlak, vibrace a další. Data získána z těchto senzorů poskytují informace v reálném čase o stavu zařízení a tvoří základ pro analýzu prediktivní údržby.
- **Předzpracování dat (Data Preprocessing):** Surová data získaná ze senzorů často obsahují šum a nekonzistence. Předzpracování dat je první krokem v případě dat pro analýzu. Zahrnuje to čištění dat, normalizaci, a zpracování chybějících dat. Vysoce kvalitní data jsou zásadní pro přesné modelování PdM.
- **Algoritmy AI (AI Algorithms):** Algoritmy AI, včetně technik strojového a hlubokého učení, jsou „mozky“ systémů PdM. Tyto algoritmy analyzují data, aby identifikovaly nejdůležitější rysy související s možnými selháními. Učí se z historických dat, aby předpovídaly selhání zařízení, anomálie a zbývající užitečnou živnost (RUL)
- **Moduly pro rozhodování (Decision-Making Modules):** Náhledy a předpovědi generované algoritmy AI jsou zpracovány moduly pro rozhodování. Tyto moduly jsou zodpovědné za určení, kdy jsou potřebné údržbové akce.

Mohou doporučit preventivní nebo opravné údržbové úkony, plánovat údržbu a v případě potřeby upozornit údržbové týmy.

- **Komunikace a integrace (Communication and integration):** Zajišťuje, že náhledy generované systémem jsou efektivně převedeny na akce. Tato komponenta zahrnuje interakce s různými zúčastněnými stranami, včetně údržbového personálu a managementu. Dále integrace s podnikovými systémy, jako jsou ERP a software pro správu aktiv, sladí prediktivní údržbu s širšími organizačními cíli.
- **Uživatelské rozhraní a reportování (User Interface and Reporting):** Aby byly tyto náhledy přístupné údržbovému personálu a rozhodovacím pracovníkům, jsou nezbytné uživatelské rozhraní a nástroje pro reportování. Tyto nástroje usnadňují uživatelům pochopení složitých vzorců dat a umožňují informované rozhodování prostřednictvím vizualizace dat, dashboardů a reportovacích schopností. (Ucar et al., 2024)

Přehled klíčových součástí lze vidět na obrázku č.1.



Obrázek 1 Klíčové součásti prediktivní údržby založené na umělé inteligenci (Zdroj: Ucar et al., 2024)

3 KONTROLA KVALITY A JEJÍ SPOJENÍ S UMĚLOU INTELIGENCÍ

Tahle kapitola stručně popisuje propojení kontroly kvality a umělé inteligence.

3.1 Kontrola kvality

S nárůstem moderních výrobních systémů a rozvojem velmi složitých produktů zaujímá řízení kvality zásadní roli v organizačním plánování a strategiích. Kontrola kvality (QC) je proces, který zahrnuje stanovení standardů kvality, zajištění že produkt tyto standardy splňuje a zlepšení celkové kvality produktu. Inspekce kvality je součástí procesu QC, při kterém je produkt kontrolován operátory v různých fázích výroby. Celý proces QC se neustále mění kvůli dynamické povaze výrobního prostředí. Přístupy jako Design experimentů (DoE), analýza možného výskytu a vlivu vad (FMEA), Quality Function Deployment (QFD) a vzorkování pro přijetí stanovují vlastní metodiky pro inspekci produktů. I když tyto metody byly v QC velmi úspěšné, nyní existuje možnost posoudit 100 % produktů na moderním výrobním pracovišti. Neustále hodnocení kvality produktu se stalo skutečností díky rozvoji sítí senzorů a umělé inteligence. (Sundaram, Zeid, 2023)

3.2 Chytrá kontrola kvality a její fáze

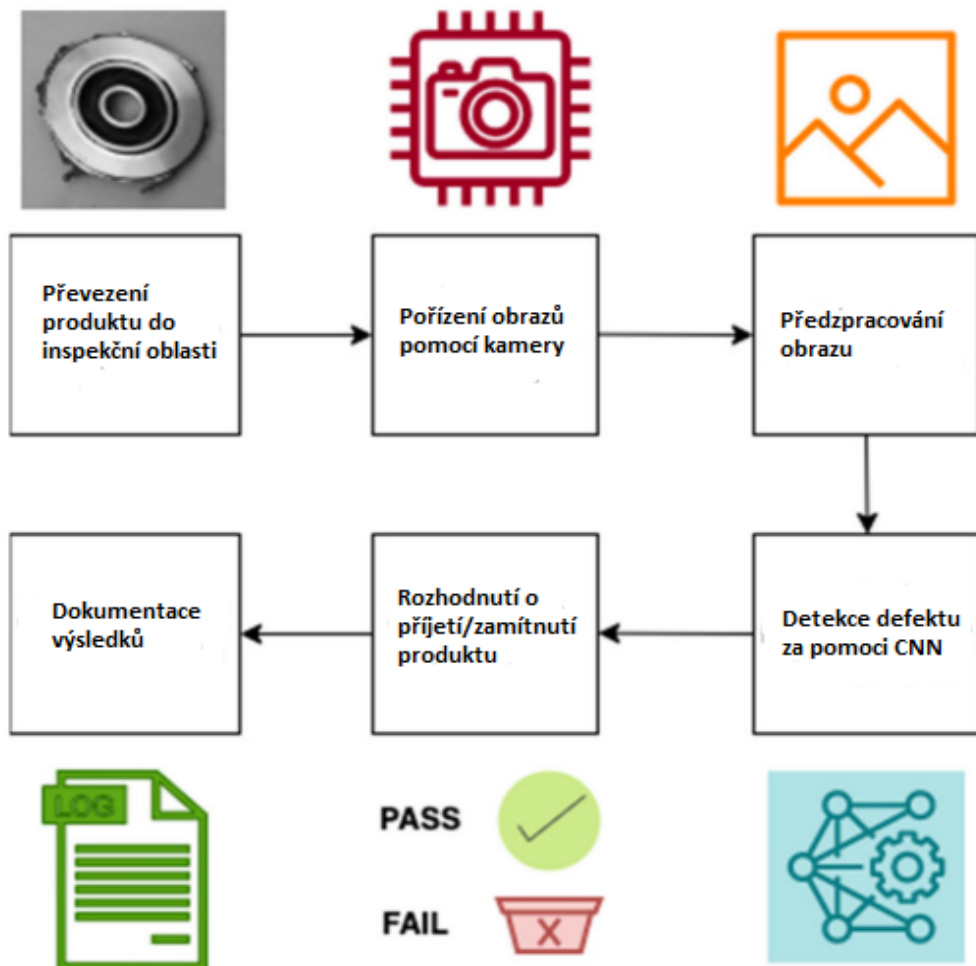
Přístup Smart Quality Inspection (SQI) má za cíl zlepšit výkon modelu a řešit několik faktorů, které ovlivňují proces vizuální inspekce. (Sundaram, Zeid, 2023)

Implementace SQI do oblasti výroby se podle autorů článku „Artificial Intelligence-Based Smart Quality Inspection for Manufacturing“ Sundarama a Zeida (2023) dělí celkem na šest etap:

- 1.Etapa: V první etapě je produkt převezen z montážní linky do inspekční oblasti. Produkt je umístěn na určené místo, aby mohl začít inspekční proces.
- 2.Etapa: V této etapě je použita vysoce kvalitní kamera k zachycení obrazů produktu, který podléhá inspekci. Podmínky osvětlení a vzdálenost od produktu jsou měřeny na základy velikosti produktu a použitého kamerového vybavení
- 3.Etapa: Předzpracování obrazu, určuje se, zda by bylo vhodné použít šedotónové nebo barevné obrázky na základě dostupnosti výpočetních zdrojů a požadované přesnosti a přesnosti predikcí. Jakákoliv úprava nebo transformace je provedena v této fázi – převrácení, stříhání, rotace, posuny, bělení, úprava kontrastu apod.

- 4.Etapa: Detekce defektů: K detekci defektů na obrázcích se používá vlastní architektura CNN (Convolutional Neural Network). Architektura má flexibilitu zvládnout různé typy obrázků s jen malým počtem změn. Model je trénován na obrázcích vadných a nevadných produktů, aby se naučil nezbytné reprezentace funkcí. Model detekce defektů je vestavěn do aplikace, která může být použita na výrobní ploše, aby byl proces bezproblémový.
- 5.Etapa: Etapa rozhodování o přijetí/zamítnutí produktu. Operátor kontroluje produkt pomocí algoritmu pro detekci defektů a okamžitě obdrží výsledky inspekce z počítačové aplikace. Na základě výsledků je učiněno rozhodnutí o přijetí nebo zamítnutí produktu.
- 6.Etapa: Dokumentace výsledků v inspekčním protokolu. Výsledky inspekčního procesu jsou zadány do aplikace SQI a automaticky uloženy do tabulky.

Metodologie SQI lze vidět na obrázku č.2.



Obrázek 2 Metodologie SQI (Zdroj: přeloženo ze Sundaram, Zeid, 2023)

4 OBLASTI UMĚLÉ INTELIGENCE NEURAL NETWORKS, COMPUTER VISION, MACHINE LEARNING A DEEP LEARNING


Kapitola obsahuje popis těchto oblastí umělé inteligence, aby bylo snazší pochopit následující řešení.

4.1 Neural Networks (Neuronové sítě)

Neuronové sítě (v angličtině Neural Networks) jsou oblastí umělé inteligence, která je silně inspirována a modelována podle fungování lidského mozku. Využívá sítě napodobující biologické neurony, které se nachází v každém mozku, k učení a pochopení vzorů (Zelinka, 2003)

Používají se ke zpracování a interpretaci dat a často ve spojení s jinými typy UI k vytváření složitějších modelů. Neuronové sítě lze použít k různým účelům, včetně rozpoznávání obličejů, zpracování přirozeného jazyka a strojového učení. Jsou složité a často vyžadují mnoho tréninkových dat, aby byly efektivní. Protože jsou však všestranné a za poslední dobu jejich výzkum velmi pokročil, staly se neuronové sítě momentálně nejpobulárnější oblastí umělé inteligence (Barták, 2017) Porovnání biologického a umělého neuronu lze vidět na obrázku č.3

Neuronové sítě jsou obzvláště užitečné pro úlohy, které jsou pro počítače samotné obtížné, jako je rozpoznávání a porozumění obrázkům nebo textu. Počítačový program musí zahrnovat detailní popis, všechny podmínky a instrukce a není schopen si poradit s neznámým problémem. Neuronová síť je naopak schopná zareagovat na novou informaci. Bez zásahu programátora si tak sama pozmění konfiguraci programu podle naučeného řešení problému, zatímco klasický PC program je bez zásahu člověka neměnný (Zelinka, 2003)



Obrázek 3 Biologický neuron a umělý neuron (Zdroj: Nagyfi, 2018)

Umělá neuronová síť je jen velmi přibližnou napodobeninou té, jež se vyskytuje v našem mozku. Biologický neuron je ve skutečnosti daleko složitější než ten umělý. Technická napodobenina je jednoduchá jednotka, která hodnotí všechny vstupy jejich váhami. Váhy se mění na základě procesu učení. Sečtená hodnota je přenesena do neuronu, který určí vhodnou odezvu na vstupní podnět. Základem pro funkci sítě je právě učení. To se skládá ze dvou fází – adaptační a aktivační (Zelinka, 2003)

4.2 Computer Vision (Počítačové vidění)

Když počítačové vidění začínalo na počátku 70.let minulého století, bylo vnímáno jako komponent vizuálního vnímání v ambiciózním plánu napodobit lidskou inteligenci a vybavit roboty inteligentním chováním. V té době někteří průkopníci umělé inteligence a robotiky (na místech jako MIT, Stanford a CMU) věřili, že vyřešením problémů „vizuálního vstupu“ bude snadným krokem na cestě k řešení složitějších problémů, jako jsou vyšší úrovně uvažování a plánování. Podle jedné známé historky v roce 1966 Marvin Minsky z MIT požádal svého bakalářského studenta Geralda Jaye Sussmana, aby „strávil léto připojením kamery k počítači a získáním toho, aby počítač popsal, co vidí“. Nyní víme, že problém je o něco složitější. (Szeliski, 2022)

Počítačové vidění je podobor hlubokého učení a umělé inteligence, kde lidé učí počítače vidět a interpretovat svět kolem nich. Zatímco lidé a zvířata přirozeně řeší problém vidění již od velmi mladého věku, pomoc strojům interpretovat a vnímat jejich okolí prostřednictvím vidění zůstává do značné míry nevyřešeným problémem. Omezené vnímání lidského zraku spolu s nekonečně se měnícími sceneriemi našeho dynamického světa je to, co činí strojové vidění v jádru složitým. (Bandyopadhyay, 2022)

4.3 Deep Learning (Hluboké učení)

Jedná se o rozšíření pojmu strojové učení, ale na rozdíl od něj je schopen řešit komplexnější problémy. Označení hluboký (deep) znamená hloubku vrstev v neuronové síti. Proto za algoritmus hlubokého učení můžeme označit pouze neuronovou síť, která se skládá z více než tří vrstev (ta, která má pouze dvě nebo tři vrstvy, je pouze základní n. síť). Tato struktura se inspirovala reálným zpracováváním vizuálních informací v lidském mozku. Jedná se o jednu z nejvýkonnějších forem umělé inteligence, protože dokáže zpracovat masivní objem komplexních dat. Každá vrstva je schopná zpracovat jinou část problému (jedna zpracovává obraz, druhá rozumí textu) a pro dosažení hlubokého učení se systém sítí spojí, přičemž

dokáže vytvářet složitější výstupy. Problém nastává, když se v systému objeví chyba, protože neuronové sítě neumí své výsledky zdůvodnit. Není jednoduše zjistitelné, ve které části systému se stala chyba, ani to, jak ji opravit (Barták, 2017)

4.4 Machine Learning (Strojové učení)

Podle Cholleta (2019) je strojové učení oblastí umělé inteligence zabývající se algoritmy a technikami, které umožňují počítačovému systému měnit svůj vnitřní stav tak, aby zefektivnil schopnost přizpůsobení se změnám okolního prostředí. V klasickém programování se používá postup takový, že lidé zadávají pravidla a data a program poté generuje odpovědi. Ve strojovém učení jsou spolu s daty do programu vkládané odpovědi očekávané při zpracování těchto dat a program generuje pravidla. Smyslem je, že program může tato pravidla aplikovat na nová data a poskytovat tak originální odpovědi.

Porovnání klasického programu a strojového učení lze vidět na obrázku č.4.

V klasickém programování je paradigma symbolické AI takové, že lidé zadávají pravidla (program) a data, která mají být zpracovávána v souladu s těmito pravidly, a výsledkem jsou odpovědi (viz obrázek č.4) Při strojovém učení lidé vkládají data spolu s odpověďmi očekávanými při zpracování těchto dat, a výsledkem jejich zpracování jsou pravidla. Tato pravidla mohou být aplikována na nová data a poskytnout tak originální odpovědi. (Chollet, 2019)



Obrázek 4 Klasický program vs strojové učení (Zdroj: vlastní zpracování podle (Chollet, 2019)

Chollet (2019) rozděluje strojové učení do 4 kategorií:

- Učení s učitelem je nejčastější forma strojového učení, která spočívá v nalezení způsobu, jak přiřadit vstupní data k odpovídajícím výstupům na základě sady

tréninkových příkladů. Tento přístup je v současnosti převažující metodou ve strojovém učení.

- Učení bez učitele probíhá, když algoritmus nemá k dispozici odpovědi, který by se daly použít jako reference. Algoritmus se zaměřuje na analýzu dat a jejich seskupování na základě podobnosti bez možnosti ověření, zda je třídění správné. Typickými aplikacemi jsou redukce dimenze a klastrová analýza. Metody učení bez učitele jsou obvykle využívány k prozkoumání datové sady před aplikací metod pod dohledem.
- Samořízené učení je varianta učení s učitelem. Hlavním rozdílem je, že sice existují známá označení tříd, nebyly však vytvořené člověkem, ale jsou automaticky generována ze vstupních dat obvykle pomocí heuristických algoritmů.
- Posilované učení, také známé jako učení zpětnovazební, je metoda, při které nejsou označení tříd předem známy. Model se učí na základě zpětné vazby, která hodnotí rozhodnutí a snaží se tak optimalizovat výsledky akcí tak, aby maximalizoval hodnotu nějaké odměny.

5 BUDOUCNOST UMĚLÉ INTELIGENCE VE VÝROBNÍCH SPOLEČNOSTECH

Výrobní závody se stávají chytřejšími, protože společnosti stále lépe využívají umělou inteligenci (AI) k přeměně informací z různých aspektů výrobního systému na prakticky využitelné poznatky. Existují však stále mezery, které je třeba řešit, aby bylo možné AI hladce integrovat do provozu. (Arinez et al., 2020)

Arinez et al. (2020) poukazuje na pět oblastí kde jsou stále mezery:

- Analýza na úrovni systému: Machine Learning (ML) je stále více využíváno na všech úrovních hierarchie výrobního systému, ale v porovnání s úspěchy ML v konkrétních aplikacích, jako je monitorování procesů, optimalizace a prediktivní údržba, je využití omezené na úrovni rozhodování systému.
- Kvalita dat: Rostoucí dostupnost heterogenních dat ve výrobních systémech přináší nové výzvy. Data mohou obsahovat velké množství irelevantních a redundantních informací, zatímco relevantní část může chybět. Tyto problémy s kurací dat představují výzvu pro aplikaci algoritmů ML, protože dostupnost a kvalita výrobních dat mají silný vliv na výkon a vhodnost AI algoritmů ve vztahu k očekávaným výsledkům.
- Transferové učení a syntéza dat: Různé techniky AI prokázaly schopnost přesně modelovat a optimalizovat výkon systému, interpretovat lidský pohyb pro realizaci spolupráce člověka s robotem, detekovat a klasifikovat defekty a předpovídat budoucí stav stroje. Předpokládá se, že pro trénink a validaci modelu jsou k dispozici dostatečná data, ale v reálných aplikacích je často nemožné systematicky získávat data z různých provozních podmínek nebo výrobních konfigurací.
- Modelování vztahů mezi materiálem, zpracováním a vlastnostmi: Pro zajištění požadovaného výkonu finálně vyrobených dílů je vyžadováno komplexní porozumění vztahům mezi materiálem, zpracováním a vlastnostmi. Konvenční modelovací a kontrolní schémata byla vyvinuta a aplikována za účelem dosažení výrobního výkonu v přítomnosti variací v dynamice procesu a nepředvídaných nejistot.
- Podpora důvěry v umělou inteligenci: Jak AI pokračuje ve vývoji a pokroku, porozumění a interpretace výstupů nástrojů AI a souvisejících technických detailů se

stávají stále více exkluzivními pro datové vědce a podobné odborníky se specializovanými dovednostmi v tomto oboru. Často to vytváří znalostní mezeru, kdy manažeři závodů a výrobní inženýři, kteří nemají tento odborný základ, nemají schopnost pochopit a správně interpretovat význam výsledků z AI modelů v souladu s kontextem problémové oblasti.

II. PRAKTICKÁ ČÁST

6 PŘEDSTAVENÍ SPOLEČNOSTI

Společnost AGD PRINT s.r.o. je česká firma, která byla založena v roce 1994 se sídlem ve Zlíně. Mezi její hlavní specializaci patří výroba technických štítků (identifikační, popisné, ozdobné), samolepek, reklamních tabulí a etiket. Kromě velkovýroby společnost dělá i malo či jednodusovou výrobu.

Majitelkou firmy je paní Taťána Džavíková, zakladatelem firmy je pan Ing. Pavel Džavík, který je i nyní jejším jednatelem společnosti. V roce 2000 byla firma certifikována v souladu s ISO 9001 pro vývoj, výrobu a prodej technických štítků a samolepek, díky němu získala lepší výchozí postavení na trhu před konkurencí. V roce 2014 se firma v rámci Ocenění českých podnikatelek stala vítězem v kategorii Cena za inovativní řešení.

6.1 Základní údaje společnosti

Název společnosti: AGD PRINT s.r.o.

Sídlo společnosti: Dlouhé díly 395, 763 02 Zlín

Datum založení: 25.října 1994

IČO: 607 25 010

Základní kapitál: 200 000 Kč

Předmět podnikání: Výroba, obchod a služby uvedené v přílohách 1 a 3 živnostenského zákona



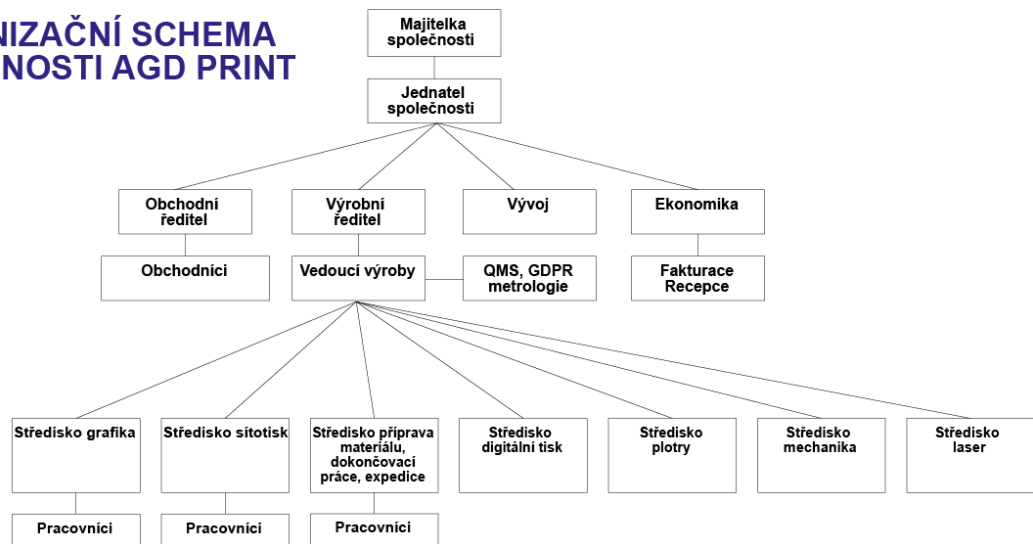
Obrázek 5 Logo společnosti AGD PRINT s.r.o (Zdroj: <https://www.agdprint.cz>)

6.2 Organizační struktura

Ve společnosti AGD PRINT s.r.o. je pouze jeden vlastník a tím je paní Taťána Džavíková. Statutárním orgánem společnosti je jednatel pan Ing. Pavel Džavík, který jedná a podepisuje se jménem celé společnosti. Firma je tvořena jednotlivými odděleními, které řídí právě jednatel. Mezi oddělení společnosti patří, jak můžeme vidět na obrázku č.6, výrobní

oddělení, obchodní oddělení, ekonomické oddělení, vývoj. Hlavní oddělení společnosti je výrobní oddělení, které se stará o samotnou výrobu, technickou přípravu výroby a logistiku ve společnosti. Za správný chod výroby je zodpovědný výrobní ředitel, pod kterého spadají výrobní oddělení, mezi které patří grafika, sítotisk, digitální tisk, plotry, mechanická dílna, laser, příprava materiálu, dokončovací práce a expedice. Oddělení vývoje má na starost QMS, GDPR a metrologii.

ORGANIZAČNÍ SCHEMA SPOLEČNOSTI AGD PRINT



Obrázek 6 Organizační struktura společnosti (Zdroj: interní materiál společnosti)

6.3 Historie společnosti

První kroky k nynější společnosti jsou datovány začátkem 90. let minulého století, kdy se dnešní jednatel společnosti pan Ing. Pavel Džavík rozhodl, že bude podnikat jako fyzická osoba. Tehdy se věnoval takzvanému Signmakingu, v češtině je to definováno jako: výroba značení a nosičů reklamního sdělení. V jeho případě se jednalo o výrobu řezané reklamy z vinylových samolepících fólií na dopravní prostředky, budovy a jiné.

V roce 1992 zakládá spolu s dalšími podnikateli společnost ANTA, s.r.o., která dodnes nabízí grafický design, výrobu orientačních systémů, polepy automobilů a výrobu světelných reklam. Pan Ing. Pavel Džavík kvůli rozdílným názorům na podnikání firmu v roce 1994 opouští a zakládá svou firmu s názvem Agentura-D, s.r.o.

Prvním sídlem firmy byl 3. ženský internát ve Zlíně, odkud se stejný rok kvůli nedostatečnému prostoru a nevyhovujícím podmínkám přesouvá na současné místo společnosti. Na počátku přebrala firma část výroby včetně zaměstnanců a odkoupila větší část strojů od jiných společností z okolí zabývajících se podobnou činností. Následně společnost Agentura-D, s.r.o. nakoupila moderní stroje z Japonska.

V roce 2011 rekonstruovali stávající budovu a došlo i na přístavbu nové výrobní haly na úrovni evropských standardů. Plocha firmy se rozšířila z 400 m² na 1000 m². Výstavba nové výrobní haly a rekonstrukce budovy byla z části dotována z fondů Evropské unie, a jejímu operačnímu programu Podnikání a inovace.

V roce 2012 se společnost přejmenovává na svůj dnešní název AGD PRINT s.r.o. kvůli vhodnějšímu propojení názvu s podstatou společnosti. Také získává statut jedné z nejlepších firem zabývajících se výrobou technických štítků, samolepek a etiket v celé České republice.

V roce 2014 společnost získává ocenění českých podnikatelek, a to cenu za inovativní řešení. Společnost rozšiřuje své působení na trhu do více zemí Evropské Unie, a to zejména Slovensko, Rakousko, Dánsko, Holandsko a mimo unijní Švýcarsko.

Během období 2020-2022 došlo k dalšímu rozšíření prostorů společnosti na 1600 m², také bylo vyměněno osvětlení, kdy se vyměnily staré žárovky za velmi úsporné LED svítidla, díky kterému společnost uspořila přibližně 60 % elektrické energie. Došlo k obměně starších digitálních tiskáren za nové LED digitální tiskárny, které mají až 6x menší spotřebu. V prostorách společnosti byl vybudován systém pro rekuperaci odpadního tepla a díky tomu je možné v zimě vytápět celé prostory kotlem, který je velikostně stejný jako ty v rodinných domech. Společnost má svou hybridní fotovoltaickou elektrárnu, která dokáže vyrobit až 50 % energie potřebné pro chod společnosti.

6.4 Nabízené produkty a služby

Společnost AGD PRINT s.r.o. nabízí následující výrobky a služby:

- **Hliníkové štítky:** Nabízejí různé varianty výroby jako je leptání, leptání a následovně vybarvení, potisk pomocí sítotisku a následné natření ochranným lakem, digitální UV potisk a následné natření ochranným lakem. Různé druhy hliníkových plechů jako je kartáčovaný plech nebo lakovaný plech a eloxovaný plech. Pomocí leptání lze docílit následujících vzhledů: lesklé písmo a zbytek štítku matný, odleptané písmo a zbytek plochy lesklý, nebo kombinaci lesklých a matných ploch.
- **Nerezové štítky:** varianty zhotovení nerezových štítků, potisk nerezí, leptání, leptání a následující vybarvení, hluboké leptání. Výsledné vzhledy jsou pak stejné jako v případě hliníkových štítků. Lze si vybrat z následujících druhů nerezového plechu: mořený, kartáčovaný, broušený, lesklý, zrcadlově lesklý, který je nejvíce poptávaný.

- **Mosazné štítky:** Varianty výroby mosazných štítků potisk buďto pomocí sítotisku anebo digitálního UV, potisk a následující nanesení ochranného laku a gravírování. Výsledný vzhled mosazného štítku díky přelakování celé plochy silnou vrstvou speciálního laku štítek získá plasticitu a je chráněn před korozi.
- **Polykarbonátové štítky:** Výhodou polykarbonátového štítku je že požadovaný motiv se tiskne zrcadlově otočený na zadní stranu polykarbonátové fólie a na konec se přetiskne požadovanou barvou podkladu. Díky tomu na pohledové straně je tisk chráněn fólií, který zabrání otěru a působení venkovního prostředí. Ze zadní strany lze aplikovat samolepící vrstvu která umožní jednoduchou aplikaci štítku na požadované místo.
- **Polyesterové štítky:** Oproti polykarbonátové variantě je více odolná nejčastějším rozměrem je kreditní karta. Každá kartička může být personifikována mít své identifikační číslo nebo může být vybavena čipem.
- **Řezaná reklama:** Samolepky z různých druhů materiálu jako jsou PVC, polyester, polykarbonát. Předností společnosti AGD PRINT s.r.o. je schopnost tisknout i bílou barvu, díky tomu dokážou vyhovět i velmi náročným požadavkům zákazníka.
- **Další výrobky:** Cedule EU, tabla, pamětní cedule, které lze zhotovit z vícero materiálů jako je PVC, plexisklo, hliník, mosaz. Potisk reklamních předmětů: USB flash disk, propisky, zapalovače, vizitky, CD a DVD.
- **Služby a technologie nabízené společností AGD PRINT s.r.o.:** Digitální UV tisk, sítotisk, speciální tisk, UV lakování jak plný formát, tak i částečný lak, řezání s elektronickým kamerovým zaměřováním, číslování štítků, děrování štítků, zakulacování rohů, nános ochranných nástřiků ke zvýšení ořezuvzdornosti povrchů, případně chemické odolnosti, laminování.

7 ANALÝZA OBECNÉHO PROSTŘEDÍ POMOCÍ SWOT ANALÝZY

Pro komplexní přehled fungování společnosti je využita SWOT analýza, samotný název jsou počáteční písmena čtyř oblastí, na které se analýza zaměřuje, a jsou to: Strengths (Silné stránky), Weaknesses (Slabé stránky), Opportunities (Příležitosti) a Threats (hrozby). Sestavení analýzy bylo realizované na základě brainstormingu s vedením firmy. Analýza slouží především pro odhalení silných a slabých stránek a aktuálních příležitostí a hrozeb, které se zde také vyskytují. Vyhodnocení jednotlivých faktorů je na stupnici od 1 do 5, kdy 1 je velmi špatné a 5 nejlepší nebo nejhorší. Přehledně celou analýzu včetně hodnocení jednotlivých bodů vedením firmy lze vidět v tabulce č.1.

Do vnitřního prostředí patří:

7.1.1 Silné stránky

Jednou z nejsilnějších stránek společnosti AGD PRINT s.r.o. je bezpochyby jejich know-how, což jsou specifické technické znalosti a dovednosti, které firma aplikuje při své výrobě, jejich know-how jim dává možnost dodávat kvalitní výrobky svým zákazníkům. Další silnou stránkou pak jsou jejich dlouholeté zkušenosti v oboru, které společnosti přináší přehled o trhu a nových trendech v oboru. Také zde patří pestrost nabízených produktů a služeb, díky čemuž může společnost oslovit různé segmenty trhu a uspokojit široké spektrum zákazníků. Dlouhodobí zákazníci jsou také důležitým indikátorem jejich schopnosti udržet si vysokou úroveň spokojenosti. Tato stabilita zákaznické základny umožňuje firmě dlouhodobě plánovat a rozvíjet se. V neposlední řadě zde patří oblast technologií a zařízení, které pomáhají zajišťovat efektivní a inovační produkční procesy. Společnost poskytuje i poradenství, které přispívá ke spokojenosti zákazníka, zahrnuje to jak technické poradenství, tak i schopnost porozumět specifickým potřebám každého zákazníka.

7.1.2 Slabé stránky

Slabé stránky společnosti AGD PRINT s.r.o. jsou zásadní pro pochopení výzev, kterým firma čelí. Jedním z hlavních problémů je psychologický odpor zaměstnanců ke změnám, což může mít za příčinu zpomalení adaptování nových technologií a inovací, díky čemuž firma může ztratit schopnost rychle reagovat na tržní změny nebo konkurenci. Společnost se zaměřuje převážně na český trh, což omezuje její potenciál růst a možnost expandovat na mezinárodní trh. Absence marketingového oddělení je také významným nedostatkem, neboť

bez silného marketingového zázemí společnost není schopna efektivně ukázat svou značku a komunikovat s lidmi v digitálním prostředí. Slabá internetová prezentace dále snižuje možnosti firmy přitahovat nové klienty a udržovat se v povědomí ve stále více digitalizovaném světě. Tyto faktory společně představují významné riziko pro udržitelnost a konkurenceschopnost společnosti.

Vnější část analýzy zahrnuje:

7.1.3 Příležitosti

Společnost AGD PRINT s.r.o. má několik zajímavých příležitostí pro rozvoj a expanzi firmy. Jednou z nejvýznamnějších je určitě získání nových zákazníků prostřednictvím marketingové kampaně a posílení internetové prezentace může firmě umožnit oslovit široké spektrum nových zákazníků. Využívání nových technologií, a to jak pokročilejších strojů a automatizačních softwarů, to by mohlo více zefektivnit operace a zvýšit produkční kapacity. Implementace umělé inteligence by mohla pomoci automatizovat některé náročné procesy a personalizovat nabídky pro zákazníky, kterým by například mohla pomoci přizpůsobit samotné produkty dle konkrétních potřeb a požadavků zákazníků. Dále má společnost příležitost se prosadit na zahraničních trzích a otevřít si dveře do nových regionů a rozšířit tak svou zákaznickou základnu. Rozvoj udržitelných a ekologických tiskových řešení, což by mohlo oslovit zákazníky preferující ekologické produkty. Nakonec spolupráce s novými dodavateli může zlepšit dodavatelské řetězce a snížit provozní a výrobní náklady. Tyhle kroky by mohly významně přispět k růstu a prosperitě společnosti AGD PRINT s.r.o.

7.1.4 Hrozby

Společnost čelí několika významným hrozbám, které mohou ovlivnit její stabilitu a možnost růstu. Jednou z nejvýznamnějších je určitě konkurence v jejich oboru, kdy je společnost nucena neustále přinášet něco nového a speciálního oproti její konkurenci, aby si udržela svou konkurenceschopnost. Další výzvou je zvyšování cen energií a růst ceny vstupních materiálů, kdy by společnost měla vyšší provozní náklady a mohlo by to způsobit například menší marže na výrobcích nebo zvýšení cen, což by mohlo být jedním z důvodů ztráty zákazníků, nebo i jednou z příčin propouštění zaměstnanců. Legislativní opatření představují potencionální riziko, neboť nové regulace by mohly vyžadovat nákladné úpravy procesů nebo výrobních zařízení. Mohla by přijít ekonomická krize, díky které by mohlo dojít k omezení celkové poptávky po nabízených produktech a službách společnosti.

Tabulka 1 Swot analýza (Zdroj: vlastní zpracování)

Silné stránky STRENGTHS	Koeficient	Hodnocení	Slabé stránky WEAKNESSES	Koeficient	Hodnocení
Know-how	0,3	5	Psychologický odpor zaměstnanců ke	0,33	3
Dlouholeté zkušenosti	0,27	5	Zaměření především na domácí trh	0,27	4
Pestrost nabízených výrobků a služeb	0,13	4	Absence marketingového oddělení firmy	0,2	5
Dlouhodobý zákazníci	0,12	3	Internetová prezentace	0,2	4
Technologie a zařízení	0,1	3			
Poradenství	0,08	4			
SOUČET	1	4,06	SOUČET	1	3,17
Příležitosti OPPORTUNITIES	Koeficient	Hodnocení	Hrozby THREATS	Koeficient	Hodnocení
Získání nových zákazníků	0,28	5	Konkurence	0,28	3
Využívání nových technologií	0,25	4	Zvyšování cen energií	0,2	4
Umělá inteligence	0,2	4	Zvyšování cen vstupních materiálů	0,2	4
Prosazení se na zahraniční trh	0,13	4	Legislativní opatření	0,13	3
Udržitelné výrobky	0,08	3	Ztráta zákazníků	0,1	5
Spolupráce s novými dodavateli	0,06	3	Ekonomická krize	0,09	5
SOUČET	1	3,98	SOUČET	1	3,37

Po zhodnocení SWOT analýzy, je patrné, že největší celkové hodnocení vyšli u silných stránek a příležitostí podniku. Silné stránky mají celkový index 4,06, příležitosti pak 3,98. Navrhuje se tedy využít strategii SO, která se zaměřuje na využití příležitostí za podpory

silných stránek. Pozornost by se měla zaměřit na realizaci nejatraktivnějších příležitostí, které pomohou zkvalitnit celkový chod společnosti a můžou pomoci ke zlepšení konkurenceschopnosti, důraz by měl být kladen i silným stránkám, které už jsou momentálně na největší úrovni. Nesmí se přehlédnout ani hrozby, kde by bylo vhodné se zaměřit na ty nejzávažnější z nich.

8 ANALÝZA SOUČASNÉHO STAVU KONTROLY KVALITY

Ve společnosti AGD PRINT s.r.o. kladou velký důraz na kontinuální kontrolu kvality svých výrobků. Proces kontroly se neomezuje pouze na jednu fázi výroby, ale začíná již před samotným začátkem výroby přes kontrolu kvality při samotné výrobě až po finální kontrolu kvality a následné balení a expedici.

8.1 Předvýrobní fáze kontroly kvality

Tahle fáze je velmi důležitá pro včasnou identifikaci a předcházení potenciálním problémům, jež by mohly vzniknout a zároveň by mohly ovlivnit kvalitu finálního produktu. Předvýrobní fáze kontroly kvality zahrnuje několik klíčových aspektů.

8.1.1 Kontrola grafiky a textu

Každý grafický návrh, který společnost AGD PRINT s.r.o. dostane od zákazníka je kontrolován grafickým oddělením společnosti, aby se zjistilo, jestli jsou všechny elementy graficky korektní, například zarovnání textu k ostatním grafickým prvkům, dostatečné rozlišení pro zachování ostroty při tisku, správné použití barev apod., a zjišťuje se, zda je návrh technicky proveditelný.

Obsah kontroly:

- **Ověření textů:** veškerý text se kontroluje, zda je bez překlepů, má správnou velikost, aby splňoval minimální velikost fontu, která je důležitá pro tiskové procesy.
- **Grafické prvky:** kontroluje se hlavně, jestli prvky mají dostatečné rozlišení a zda-li jsou vhodné pro zvolenou techniku výroby. Některé prvky mohou být příliš jemné nebo složité pro danou technologii výroby.
- **Mezery:** kontrolou se zajistí dostatečné mezery mezi čarami a grafickými prvky tak, aby se předešlo nesrovnalostem v tisku.
- **Kontrola rozměrů:** digitální návrhy jsou pečlivě přeměřeny a porovnány se specifikacemi výrobku.
- **Otvory pro uchycení:** kontroluje se správné rozmístění a jejich počet, aby se zajistilo, že štítky půjdou správně namontovat na dané místo.

8.1.2 Výběr materiálů

Volba vhodného materiálu je klíčová pro funkčnost a estetiku finálního produktu. Každý z materiálů nabízených společností AGD PRINT s.r.o. byl otestován, aby byla zajištěna životnost povrchových úprav výrobků. Materiál musí splňovat estetické požadavky zákazníka a zároveň musí být vhodný pro účel štítku. Také se zde rozhoduje mezi různými povrchy materiálu, aby byly splněny všechny požadavky. Při náročných zakázkách se nejprve vyrobí zkušební vzorek, než se spustí výroba celé zakázky, aby se zajistila maximální spokojenost zákazníka.

8.2 Průběžná kontrola kvality

Kontrola během samotné výroby je rozhodující pro včasné zachycení případných problémů, které by mohly nastat v průběhu samotné výroby, minimalizovat tak výrobu zmetků a zároveň tak zajistit výslednou kvalitu výrobků. Probíhá přímo za chodu stroje, kde se vizuálně kontroluje, jestli je všechno tak, jak má být.

Obsah kontroly při výrobě na digitální UV tiskárně:

- Kontroluje se hlavně ostrost natisknutého vzoru a dále textu a také správná barevná konzistence.
- Klade se důraz na včasnou detekci a tím předcházení problémů s překrýváním barev (soutiskem) a chybějícími oblastmi tisku (nedotiskem), zahrnuje to i pravidelnou kalibraci využívaných zařízení a kontrolu správného nastavení tiskových válců a desek.

Obsah kontroly při výrobě pomocí techniky sítotisku:

- Před zahájením procesu pracovníci na daném pracovišti pečlivě kontrolují stav tiskových sít pro odhalení případného poškození nebo ucpaných otvorů, které by zapříčinily nekvalitní tisk, také se prověřuje správné napětí sítě, které je důležité pro dosažení precizního a rovnoměrného přenesení barev.
- Během samotného tisku je pracovníky sledována kvalita tisku, která zahrnuje ostré vyobrazení jeho detailů, konzistenci barev a případné chyby jako je rozostření a nedotisky, které se dají včas opravit.
- Kontroluje se také správně nastavené teploty v pecích, pro dostatečné zapečení obtištěného výrobku.

Obsah kontroly při vyrábění pomocí laseru:

- Sleduje se průběh laserového řezání a gravírování, aby bylo dosaženo precizních a čistých okrajů produktu, a taky případného vzoru nebo textu.
- Operátor sleduje a současně je také zodpovědný za správné nastavení samotného stroje, a to obsahuje vhodné nastavení paprsku k použitému materiálu, aby byl správně paprsek zaostřený a díky tomu se zajistí plynulý řez, který bude stejně intenzivní po celé ploše řezu a správně zvolenou rychlost řezu dle tloušťky materiálu.

Obsah kontroly při výrobě na plotru:

- Sleduje se přesnost řezu tak, aby bylo dosaženo čistých a přesných okrajů bez poškození materiálu, je potřeba zkontrolovat správné nastavení plotru a pravidelně provádět údržbu řezných čepelí, aby se předešlo špatným řezům kvůli nedostatečně ostré čepeli.
- U štítků se samolepící vrstvou je důležité, aby se při řezu nepoškodil ochranný silikonový papír, mohlo by to zkomplikovat finální montáž štítku.

Obsah kontroly při výrobě v mechanické dílně:

- Před zahájením výroby se kontroluje technická dokumentace pro zajištění toho, že všechny výrobní postupy a rozměry jsou správně definovány.
- Po nastavení strojů a spuštění výroby se podrobně kontroluje první kus, jestli odpovídají rozměry, geometrie, případně se testuje i funkčnost. Když se zjistí, že něco nesplňuje požadavky, upravuje se výrobní postup nebo se přenastaví celé výrobní zařízení.
- V průběhu výroby se provádí časté měření a kontroly výrobních tolerancí, také rozměrů za použití kalibrovaných měřících nástrojů jako jsou mikrometry nebo například posuvná měřítka.

8.3 Kontrola finálního výrobku

Provádí se finální vizuální kontrola, kde je každý štítek pečlivě prohlédnut pro případ vizuálních vad jako jsou nedotisky, špatně aplikovaný lak, nečistoty nebo chyby v barvě potištěné plochy, dbá se na kontrolu správnosti natištěné grafiky, textu a celkové estetiky produktu.


Při výrobciích, které obsahují QR a EAN kódy je kontrolováno pomocí čteček čitelnost a správná funkčnost. Kontroluje se také správný počet vyrobených kusů, aby odpovídal množství dle objednávky zákazníka.

Provádí se finální ověření rozměrů samotného štítku a otvorů pro uchycení, kde se přeměřuje správný průměr a zjišťuje se jejich počet. Provádí se také kontrola správně naneseného ochranného laku a povrchu tisku, aby na něm nebyly nečistoty a byla správná adheze (přilnavost) barvy.

U výrobků řezaných na plotru se ještě navíc kontroluje, jestli není narušený silikonový papír.

Všechny výsledky finální kontroly jsou dokumentovány, dokumentace zahrnuje záznam o provedených kontrolách a případné korekce, které musely být provedeny. Tato dokumentace je důležitá pro správné řízení kvality. Ukázku formuláře výstupní kontroly lze vidět na obrázku č.7.

Po finální kontrole kvality následuje balení a příprava pro expedici. Produkty jsou baleny s největším úsilím ochrany produktu během transportu, jsou baleny tak, aby to odpovídalo citlivosti dané zakázky. Využívají se ochranné materiály jako jsou bublinkové obálky, různé typy ochranných fólií, pevné kartonové krabice a další prostředky k zabránění poškození výrobku.

	FORMULÁŘ VÝSTUPNÍ KONTROLY	Strana: 1/1
	Řízený dokument pouze v elektronické podobě, v tištěné podobě pouze informativní	Výtisk č.: 1

Firma			
Výrobek	Potisk dílce štítek XYZ		
Zakázka	2024/xxxx	Číslo výrobku v zakázce	1

PROVEDENÉ KONTROLY

Grafika (texty, mezery, počet čar)	<input checked="" type="checkbox"/>	
Materiál	<input type="checkbox"/>	
Rozměry, otvory (počet, průměr)	<input type="checkbox"/>	
Kvalita tisku, soutisku, nedotisky	<input checked="" type="checkbox"/>	
Lak, nečistoty	<input type="checkbox"/>	
Barevnost	<input checked="" type="checkbox"/>	
Přilnavost (adheze) barvy	<input checked="" type="checkbox"/>	
Počet kusů	<input checked="" type="checkbox"/>	
Čitelnost QR, EAN kódu	<input type="checkbox"/>	
Řez plotru, narušení silikon. papíru	<input type="checkbox"/>	
	<input type="checkbox"/>	
	<input type="checkbox"/>	
	<input type="checkbox"/>	

Protokol vyhotovil		
Datum		

Obrázek 7 Formulář výstupní kontroly (Zdroj: interní materiály společnosti)

8.4 Analýza finální kontroly kvality štítku XYZ

Právě finální kontrola byla zvolena z důvodu nejvhodnějšího místa pro zavedení umělé inteligence. Finální kontrola kvality štítku XYZ zajišťuje, že výsledný produkt odpovídá specifikacím a je bez vad. Každá část kontroly se zaměřuje na konkrétní aspekty štítku a vyžaduje od kontrola kvality pečlivost a pozornost. Vývojový diagram téhle kontroly lze vidět v příloze P I.

Detailní rozebrání kontroly:

- Při kontrole grafické části štítku kontrolor porovnává výsledný produkt s technickou dokumentací a prověřuje, zda jsou všechny texty dobře čitelné a zda odpovídají rozměrům ze zadání. Doba téhle kontroly byla změřena na 30 sekund na štítek, jelikož se jedná o štítek, kde je text v délce 4 znaků.
- Kontrola kvality tisku je detailnější vizuální kontrolou, kdy kontrolor hledá místa, kde by mohlo dojít k nežádoucímu spojení barev (soutisk) nebo k chybějícímu tisku (nedotisku) a také kontroluje, zda tisk není rozmazaný a zda neobsahuje bubliny, skvrny nebo jiné defekty. Tahle kontrola je prováděna s pomocí lupy a byla naměřena doba trvání 40 sekund na jeden štítek.
- U kontroly barevnosti štítku se porovnává barva štítku s kontrolním vzorem, aby se zajistilo, že barvy nejsou bledé, nezměnily odstín a jsou konzistentní po celé zakázce. Doba pro tuhle kontrolu byla naměřena na 20 sekund na kus.
- Pro kontrolu přilnavosti (adheze) barvy se používá lepicí páska, která se po přibližně 15 vteřinách strhne a následně se štítek zkontroluje, zda nikde nechybí barva. Bylo naměřeno 35 sekund včetně nalepení lepicí pásky na štítek.
- Kontrola množství je relativně jednoduchá, ale zásadní. Kdy při měřené zakázce kontrolor fyzicky počítal 25 štítků v zakázce a trvalo to 18 sekund.

Kontrola jednoho štítku tedy při měřené zakázce trvala 125 sekund bez kontroly počtu kusů, neboť ta se provedla následně po zkontrolování všech 25 štítků.

Doba pro zkontrolování celé zakázky činila 3143 sekund tedy přibližně 52 minut. Přehledně dobu každé operace lze vidět v tabulce č.2.

Výrobky z analyzované zakázky neobsahovaly žádný defekt, lze tedy předpokládat, že zakázka s defektem by mohla prodloužit finální kontrolu kvality.

Tabulka 2 Doba měřené finální kontroly (Zdroj: vlastní zpracování)

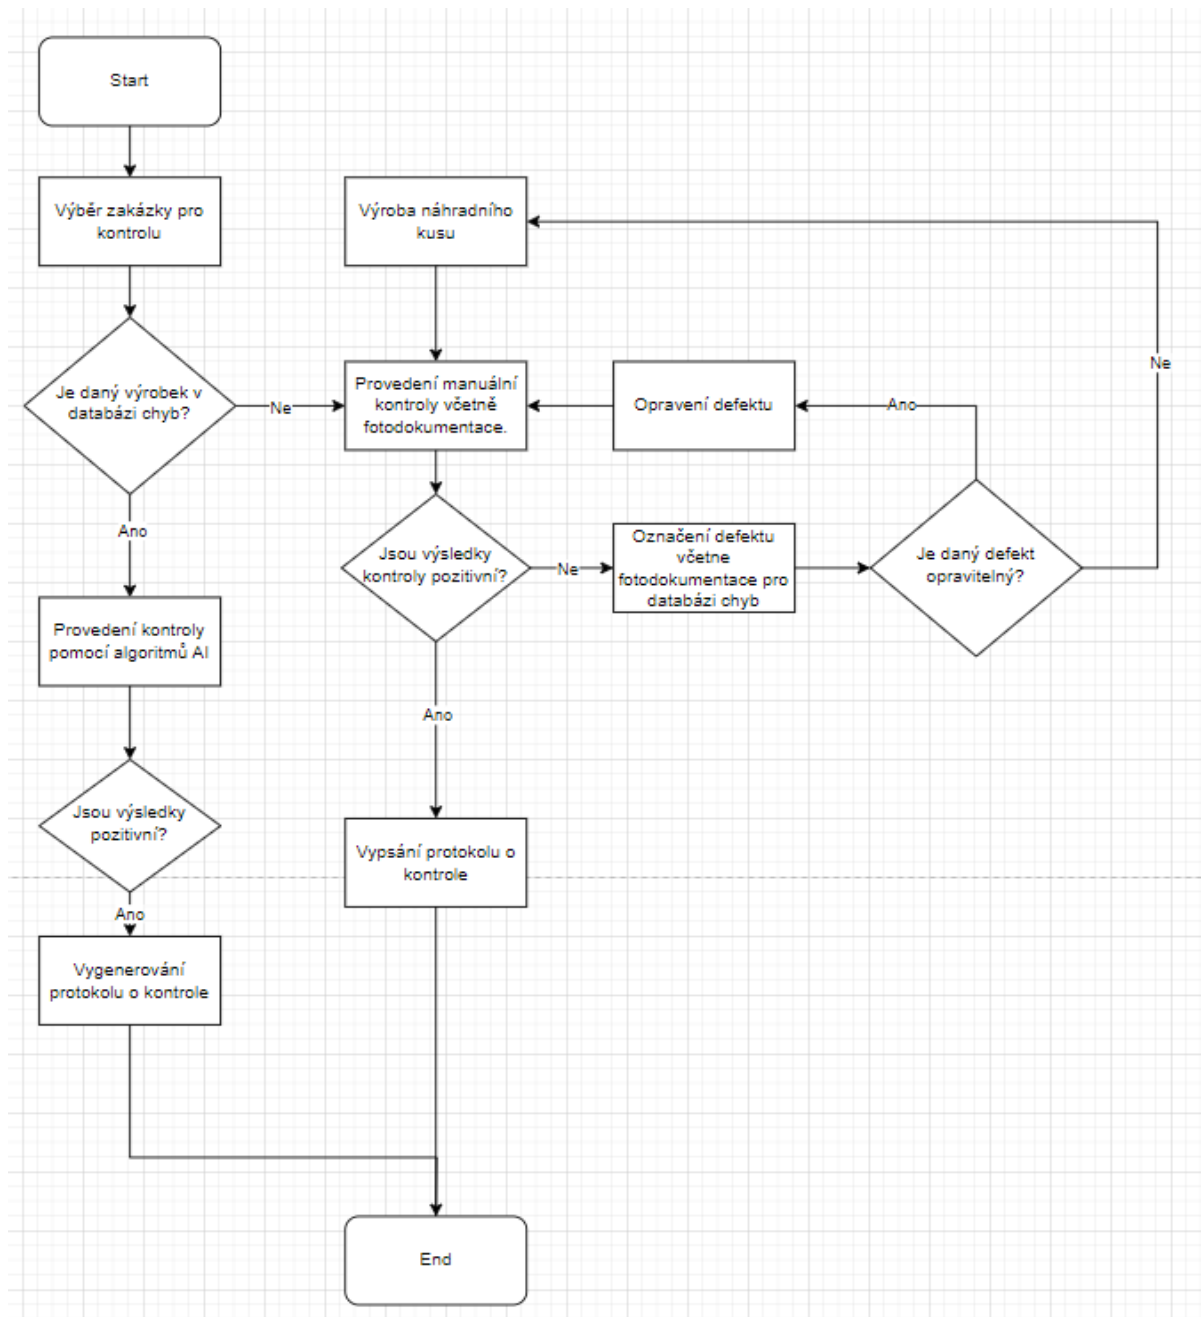
Prováděná kontrola	Pro 1 ks	Pro celou zakázku [25 ks]
Grafika	30 s	750 s
Kvalita tisku	40 s	1000 s
Barevnost	20 s	500 s
Přilnavost barvy	35 s	875 s
Počet kusů	X	18 s
Celkem	125 s	3143 s (52:23 min)

Po finální kontrole následuje vyplnění výstupního formuláře výstupní kontroly (viz. Obrázek č.7) kde v případě vyskytnutého defektu kontrolor řádně vyplní popis defektu a předá to zpět do výroby kde se rozhodne, jestli je daný defekt opravitelný anebo se musí vyrobit nový kus.

9 NÁVRH ŘEŠENÍ VEDOUCÍ K ZAVEDENÍ AI V OBLASTI KONTROLY KVALITY

Na základě teoretického pozadí a úvodních analýz bude vytvořen návrh, díky kterému bude možné implementovat kombinaci počítačového vidění a umělé inteligence pro kontrolu kvality ve výrobní společnosti. Finální kontrola byla zvolena společností z důvodu druhu výroby společnosti AGD PRINT s.r.o. kdy nemají výrobní linky kde by bylo vhodnější začlenit kontrolu pomocí umělé inteligence přímo do výrobní linky, ale zaměřují se na výrobu High-Mix Low-Volume (vysoká variabilita, nízký objem), kde by bylo obtížné nasadit umělou inteligenci přímo do výroby z hlediska velké variability proměnných ve výrobě a z tohoto důvodu tak nejvhodnějším místem pro implementaci je právě finální kontrola kvality, kde je největší překážkou shromáždění různých defektů pro vytvoření databáze chyb a je zde největší prostor pro úsporu času jelikož v současné době je finální kontrola kvality vykonávána manuálně tak i s časem (naměřený čas při kontrole měřené kontroly štítku XYZ lze vidět v tabulce č.2) je zde prostor pro celkové zlepšení výsledné kvality zamezením lidských chyb.

Pro lepší pochopení, jak samotný návrh bude fungovat, je důležité vytvořit vývojový diagram, který ukáže, jak postupovat při samotné kontrole. Vývojový diagram návrhu lze vidět na obrázku č.8. Na vývojovém diagramu lze ihned vidět, že nebude vhodné využít nástroj pro kontrolu výrobní zakázky, která ještě nebude mít svoji fotodokumentaci v databázi chyb, neboť celý návrh funguje na principu porovnání toho, co nástroj „vidí“ s tím, co má ve své databázi, která obsahuje jak fotodokumentaci výrobku, který neobsahuje defekt, tak i výrobek na kterém je defekt, který je označen v souboru s anotacemi k dané fotografii. Když se bude kontrolovat nějaká nová zakázka, která má méně kusů, tak si společnost bude muset určit, jestli se vyplatí pro případ, že by se daná zakázka opakovala zahrnout daný výrobek do databáze nebo postačí jen manuální kontrola kvůli malému počtu kusů.



Obrázek 8 Vývojový diagram návrhu implementace (Zdroj: vlastní zpracování)

9.1 Databáze defektů

Prvním a zároveň nejdůležitějším krokem pro zavedení návrhu je tedy vytvoření databáze chyb, které se objeví při manuální kontrole kvality. Každou chybu, kterou kontrolor kvality objeví, bude muset udělat fotodokumentaci a řádně označit všechny chyby na dané fotografii a řádně označit název fotografie značkou, která se bude používat pro daný výrobek, aby bylo možné při opětovném objednání stejné zakázky již provést kontrolu pomocí umělé inteligence. Samotná databáze by měla být zorganizována do několika hlavních částí:

- Fotodokumentace: Sbíрка pořízených fotografií produktů, které zahrnují jak bezchybné kusy, tak i kusy s různými druhy defektů. Fotografie by měly být ve vysokém rozlišení a z různých úhlů, aby bylo dosaženo pokrytí všech možných scénářů, se kterými se může systém setkat.
- Anotace: Pro každou fotografii bude muset vzniknout soubor s anotacemi, který specifikuje polohu a druh vzniklých defektů. Tenhle soubor by měl obsahovat informace jako jsou druhy defektů (např. prasklina, škrábanec), kdy samotný zápis je velice jednoduchý a stačí jen přepsat hodnoty ve vytvořené šabloně a uložit soubor pod názvem spojeným s fotografií.

V šabloně je potřeba správně přiřadit název souboru s fotografií a dále jen označit, co to je za druh defektu v řádku „label“, v řádku „shape“ se nebude měnit nic, jelikož rectangle (obdélník) je univerzální označení pro místo s defekty a pak už se jen doplní souřadnice X a Y, kde na fotografii se defekt nachází s uvedením velikostí šířky a výšky defektu. Ukázku šablony lze vidět na obrázku č.9.

```
"image": "produkt_00123.jpg",  
  "annotations": [  
    {  
      "label": "prasklina",  
      "shape": "rectangle",  
      "coordinates": {  
        "x": 150,  
        "y": 200,  
        "width": 50,  
        "height": 10  
      }  
    },  
  ],
```

Obrázek 9 Ukázka anotace
(Zdroj: vlastní zpracování)

- Konstantní podmínky: Při snímání fotografií je potřeba to dělat v konzistentních světelných podmínkách se stejným pozadím, zlepši se tím schopnost modelu převést tréninková data do následné reálné kontroly.
- Údržba a aktualizace databáze: Postupem času, jak se budou objevovat nové typy defektů, je potřeba tenhle proces dělat neustále, aby měl nástroj aktuální informace pro kontrolu. Stará nebo dlouho nepoužitá data mohou být přenesena do archívu, aby databáze zůstala přehledná, a také se uvolnilo případně potřebné uložště.

9.2 Softwarová část návrhu

Na softwarové části systému kontroly kvality lze pracovat zároveň s vytvářením databáze defektů. Pro část zodpovědnou za sběr a předzpracování obrazu jsem pro tenhle návrh zvolil volně přístupnou knihovnu pro počítačové vidění OpenCV.

9.2.1 Představení OpenCV

OpenCV (Open Source Computer Vison Library) je nejstarší a nejvíce populární knihovnou v tomto odvětví, poskytuje velké množství nástrojů pro zpracování obrazu a strojového učení. Od svého vzniku v roce 1999 si našla uplatnění v širokém spektru aplikací, od průmyslové automatizace, přes bezpečnostní systémy, rozpoznávání obličejů, zpracování obrazu, detekce a rozpoznávání objektů. OpenCV nabízí velké množství již optimalizovaných algoritmů pro široké spektrum aplikací v oblasti počítačového vidění a strojového učení. Jednou z hlavních předností OpenCV je možnost zpracovávat obrazy nebo i videa v reálném čase. To je zásadní i pro můj návrh, kde je cílem, aby to bylo rychlejší než manuální kontrola prováděná s kalibrovanými měřidly. Knihovnu lze použít na mnoha různých platformách, jako je Windows, Linux, Mac OS. OpenCV podporuje několik programovacích jazyků včetně C++, Python, Java a další. Takže i případné úpravy modelu lze provést přímo ve firmě, jelikož disponuje IT specialistou, který tyto jazyky ovládá. Dalším bodem při rozhodování byla aktivní komunita vývojářů, kdy je na internetu dohledatelné velké množství návodů, které usnadňují učení se s programem a řešení případných problémů. OpenCV, jak je již z názvu zřejmé, je open-source software, což znamená, že je dostupný zdarma, což umožňuje jeho široké využití bez zbytečných právních omezení.

9.2.2 Využití OpenCV v návrhu

Pro tenhle návrh bude software OpenCV hrát zásadní roli a bude využíván pro předzpracování vstupních dat pro model umělé inteligence, který následně provede kontrolu, což zahrnuje následující:

- Načítání obrazů z různých zdrojů, včetně souborů, přímo na disku a nebo rovnou z kamery, která bude snímat plochu, kde se bude provádět kontrola kvality. Kdy má software přímo stanované funkce pro každé z nich „cv2.imread()“ je pro čtení dat z disku a pro zpracování vstupu přímo z kamery existuje funkce „cv2.VideoCapture()“.

- Standardizaci velikosti obrazu a jeho rozlišení pro zajištění konzistentních vstupů pro následnou analýzu modelem umělé inteligence. OpenCV má funkci „cv2.resize()“, která umožní upravit vstupní data na požadovaný rozměr bez poškození kvality.
- Zlepšení vizuální kvalitu obrazu, díky čemuž může pomoci provést přesnější analýzu modelem AI přímo v OpenCV je možné upravit hodnotu jasu a kontrastu u vstupních dat.
- Některé výrobky mohou vyžadovat úpravu barev pro lepší zobrazení defektů. OpenCV umožňuje převést vstupní obraz z RGB do šedo tónového prostředí.
- Detekci hran, která je užitečná pro získání strukturálních informací z obrazu.
- Software také umožňuje zobrazení výsledné kontroly přímo na počítačovém monitoru, aby se mohl kontrolor kvality i podívat, jestli produkt neobsahuje žádný defekt, případně že obsahuje, tak uvidí, kde se nachází a může pak usoudit, zda jde o opravitelný defekt, nebo je to kompletně vadný kus a musí se vyrobit nový.

Software OpenCV ovšem nestačí, jelikož nezvládne ten obraz sám o sobě analyzovat a posoudit, zda obsahuje defekt nebo je bez defektu, aby tohle bylo možné, je zapotřebí propojit OpenCV a software pro hluboké učení, jako je PyTorch nebo TensorFlow. Tyhle platformy poskytují nástroje pro trénink a nasazení modelů umělé inteligence, které na rozdíl od OpenCV mohou efektivně analyzovat vstupní data, rozpoznat složité vzory a rozhodnout o přítomnosti defektů na základě naučených charakteristik z vytvořené databáze chyb. Pro samotný návrh je potřeba si uvědomit, že se nebude jednat o velký projekt, kde by se tahle kontrola integrovala přímo na výrobní linku, ale bude se instalovat na samotném pracovišti kontroly kvality a je tedy zapotřebí si vybrat ten vhodnější framework pro strojové učení (vývojovou platformu), v závislosti na velikost projektu je potřeba se dívat hlavně na body: snadnost použití, flexibilita při upravování modelu, samotnou integraci s programem OpenCV.

9.2.3 Představení vývojové platformy PyTorch

PyTorch je vývojová platforma pro strojové učení, která se vyznačuje zejména svou flexibilitou a intuitivním rozhraním. PyTorch je oblíbený díky své podpoře dynamických výpočetních grafů, které umožňují upravovat a optimalizovat modely „za běhu“. To je

velkou výhodou i pro tenhle návrh, jelikož očekávám, že ze začátku bude potřeba daný model předělávat a dále s ním experimentovat, aby správně fungoval a usnadnil tak práci a ušetřil čas při finální kontrole kvality. PyTorch má také lepší integraci s programovacím jazykem Python, takže v kombinaci s OpenCV, kde je Python považován za nejpříznivější programovací jazyk, je příjemnější pro daného IT specialistu se v programech orientovat.

9.2.4 Představení vývojové platformy TensorFlow

TensorFlow je možná nejrozšířenější platforma pro strojové učení, která se využívá kvůli své robustnosti a schopnosti škálování od výzkumných projektů až po produkční nasazení. Platforma podporuje statické výpočetní grafy, které jsou efektivní pro produkční aplikace, ale může být problém s jeho flexibilitou pro běžné úpravy modelů v porovnání s platformou PyTorch. Stejně jako platformu PyTorch, tak i TensorFlow, lze efektivně využívat s programem OpenCV pro úlohy zpracování obrazů. Vstupní data předzpracována softwarem OpenCV lze převést do formátu vhodného pro TensorFlow, což umožňuje integraci předzpracování a následné vyhodnocení pomocí umělé inteligence do jednoho pracovního postupu.

9.2.5 Porovnání platform PyTorch a TensorFlow

Výhody platformy PyTorch:

PyTorch je známý pro svou flexibilitu a jednoduchost úprav. Jeho dynamické výpočetní grafy umožňují vývojářům snadno měnit a upravovat modely během chodu programu, což je velkou výhodou pro prototypování a experimentování. Dobře se integruje s ostatními softwary, které využívají programovací jazyk Python, což usnadňuje vývoj a snižuje učící křivku pro IT specialistu ve společnosti, který tenhle programovací jazyk ovládá.

Nevýhody platformy PyTorch:

Ačkoliv PyTorch neustále zlepšuje své nástroje pro nasazení, tradičně byl vnímaný jakožto méně vhodný pro větší projekty. Je méně rozšířený v průmyslu, jelikož se začal používat teprve nedávno pro průmyslové aplikace, zatímco TensorFlow má delší historii využití při velkých projektech.

Výhody platformy TensorFlow:

Platforma TensorFlow byla navržena s ohledem na produkční použití, což zahrnuje podporu pro nasazení modelů na různé platformy od serverů až po mobilní zařízení. Delší historie využívání v průmyslových aplikacích.

Nevýhody platformy TensorFlow:

Kvůli své komplexnosti a rozsáhlosti může být platforma TensorFlow obtížnější na naučení.

Na základě prozkoumání obou platforem je pro návrh lepší zvolit platformu PyTorch v závislosti na velikosti projektu, kvůli vyšší flexibilitě a snadnému upravování modelů v programovacím jazyce Python, který se využívá i pro software OpenCV tudíž stačí pro celý návrh pouze znalost tohoto programovacího jazyka.

Samotné propojení těchto programů je jednoduché, program OpenCV pomocí kamery sleduje produkty, které se nacházejí na vymezené kontrolní ploše, zpracovává tenhle obraz v reálném čase, identifikuje jednotlivé produkty a následně předává tyto data do modelu PyTorch, který vyhodnocuje kvalitu každého snímaného produktu a výsledky následně lze vidět na monitoru kontrola kvality.

9.3 Hardwarová část návrhu

Pro úspěšnou implementaci návrhu kontroly kvality pomocí umělé inteligence je důležité pořídit počítač s dostatečně výkonným hardwarem, který zvládne potřebné výpočty a zpracování vstupních obrazů.

9.3.1 Počítač

Pro samotný počítač je nezbytné pořídit moderní výpočetní jednotku (CPU) s dostatečným počtem jader a vysokou frekvencí pro efektivní multitasking a zpracování dat, vhodné jsou procesory společnosti Intel, konkrétně tedy Intel Core i5-12600KF by měl postačit i pro případné náročnější úlohy, pro budoucí rozšíření aplikace je to dobrý kompromis mezi výkonem a cenou. Dalším nezbytným komponentem je grafická karta (GPU), pro tenhle návrh jsou vhodné grafické karty od společnosti NVIDIA, konkrétně grafická karta NVIDIA GeForce RTX 3060, která je skvělou volbou pro tenhle návrh, jelikož poskytuje dostatečný výkon za rozumnou cenu. Potřebná základní deska má kritérium správného socketu pro umístění CPU a místo pro připojení SSD disku, který je umístěn přímo na základní desce. Zvolil jsem ASUS PRIME Z690-P D4-CSM, která je cenově dostupná a má všechna potřebná místa na připojení zbylých komponentů. Paměť RAM jsem zvolil 32 GB od společnosti Kingston, jelikož 16 GB by nemuselo stačit. Aby byla práce s daty rychlá, tak


jsem zvolil úložiště M.2 SSD disk od společnosti Kingston s velikostí úložiště 1TB, což by mělo být dostatečné pro správné fungování celého návrhu a v případě archivování již nepoužívaných dat lze přikoupit HDD disk WD Blue z velikostí 2TB, kde by se mohla data uchovávat. Je potřeba kvalitní chladič pro CPU, a pro to jsem zvolil značku Noctua a konkrétně model NH-D15, jelikož tahle společnost je známá skvělými vzduchovými chladiči. Celou sestavu bude napájet 750 W zdroj od společnosti Corsair, model RM750e a celá sestava bude ve skříni FSP Forton CST130, která v poměru své ceny dodává dostatečný výkon v podobě propustnosti vzduchu.

9.3.2 Kamera a osvětlení

Pro samotné snímání produktů při kontrole kvality v tomhle návrhu bude stačit kamera, která splňuje požadavky na dostatečně kvalitní rozlišení, kdy by 1080 p (Full HD) mělo stačit, a tím, že tohle zařízení nebude integrováno přímo do výrobní linky, ale bude to na místě kontroly kvality, tak postačí snímková frekvence 30 snímků za sekundu (FPS). Kamera by byla umístěna nad snímanou plochou a okolo ní by byl rám, na který by se umístilo přídatné LED osvětlení, aby bylo zajištěno rovnoměrně rozložené světlo tak, aby se zabránilo tvorbě stínů a zvýraznily se detaily snímaného objektu. Vybral jsem kameru od společnosti Logitech model C920 HD Pro, která je skvělou volbou pro tenhle návrh, jelikož poskytuje Full HD video záznam při 30 FPS má automatické zaostřování a dokáže si sama regulovat světlo. Tuhle kameru půjde použít i při tvorbě databáze chyb, aby bylo dodrženo požadavků na konzistentní podmínky snímaného prostředí.

9.3.3 Konstrukce zařízení

Je potřeba vytvořit konstrukci, která bude obsahovat plochu na kterou se budou pokládat kontrolované výrobky. Plocha by měla mít z každé strany jinou barvu a například tedy bílou a šedou či černou z druhé strany, aby bylo možné zajistit kontrast mezi různou škálou výrobků a díky tomu napomoci k omezení chybovosti systému. Abychom si mohli představit, jak by to mohlo vypadat vytvořím jednoduchý 3D model, který můžeme vidět na obrázku č.10.



Obrázek 10 3D ilustrační model konstrukce (Zdroj: vlastní zpracování)

10 EKONOMICKÉ ZHODNOCENÍ A RIZIKA NÁVRHU

Ekonomické zhodnocení se při tomhle návrhu vytváří obtížně vzhledem k tomu, že nejde přesně určit, jak dlouho bude trvat vytvořit už jen samotnou databázi s chybami, jelikož ty chyby se musí nejprve objevit a následně je zdokumentovat, aby bylo možné využít automatický systém.

Následně je potřeba doladit open-source algoritmy, jak programu OpenCV, tak i programu PyTorch, aby výsledné řešení správně fungovalo při kontrole kvality. Společnost má svého IT specialistu, který ovládá programovací jazyk Python. Ten je potřebný pro oba zvolené programy, tudíž náklady s nastavováním a upravováním budou levnější než při externím řešení. Co se samotných nákladů na rozjetí návrhu týče a s nimi spojené doby potřebné pro rozjetí návrhu která byla odhadována s pomocí kontrolora kvality, jelikož nejde předem určit, jak dlouho dané činnosti budou trvat. Náklady spojené s rozjetím z tabulky č.3 jsou tedy orientační a mohou se od výsledných lišit.

Tabulka 3 Náklady na rozjetí návrhu (Zdroj: vlastní zpracování)

Činnost	Odhad doby [hod]	Odhad nákladů [Kč]
Návrh řešení	10	2000
Tvorba databáze	20	5000
Doladění algoritmů (Programování)	30	30000
Celkem	65	37000

Při výpočtu nákladů spojených s rozjetím návrhu je nejdražší položkou programování, kdy mzda programátora činí přibližně 1000 Kč/hod.

Co se samotných nákladů na pořízení potřebného hardwaru týče, zhodnocení můžeme vidět v následující tabulce č.4. (všechny komponenty potřebné pro postavení počítače včetně kamery lze zakoupit na nejmenovaném e-shopu)

Tabulka 4 Náklady na pořízení hardwaru potřebného hardwaru (Zdroj: vlastní zpracování)

Položka	Model	Cena [Kč]
---------	-------	-----------

Procesor (CPU)	Intel Core i5-12600KF	4529
Grafická karta (GPU)	NVIDIA GeForce RTX 3060 12 GB GDDR6	8389
Základní deska	ASUS PRIME Z690-P D4- CSM	3390
Paměť (RAM)	Kingston FURY 32 GB DDR4	1869
Uložiště	SSD disk M.2 Kingston NV2 1TB	1549
Přídavné uložení	HDD disk WD Blue 2TB	1569
Chladič pro CPU	Noctua NH-D15	2699
Napájecí zdroj	Corsair RM750e	2790
Skříň	FSP Fortron CST130	1029
Kamera	Logitech HD Pro Webcam C920	2099
Celkem		29912

Náklady za materiál potřebný pro konstrukci zařízení můžeme vidět v následující tabulce č.5.

Tabulka 5 Náklady na materiál potřebný na konstrukci (Zdroj: vlastní zpracování)

Materiál	Cena [Kč]
Tvrdé PVC 50x50 cm	140
Ocelový jekl 15x15x1,5 mm délka 6 m	276
Celkem	416

(Tvrdé PVC a Ocelový jekl lze zakoupit na nejmenovaných e-shopech)

(Všechny uvedené ceny v tabulkách č.4 a č.5 jsou včetně DPH)

10.1 Rizika návrhu

Návrh implementace kontroly kvality pomocí umělé inteligence nabízí řadu výhod, ale také s sebou nese určitá rizika. Největším rizikem je nedostatečná databáze, jelikož systém vyžaduje velké množství kvalitních dat pro správné vyhodnocování kontrolovaných výrobků. Nedostatek nebo špatná kvalita dat může vést k nepřesnostem ve výsledcích. Nesprávné doladění algoritmů může vést ke generování chybných výstupů, což může negativně ovlivnit finální kontrolu kvality.

V případě selhání systému bude stále možné udělat finální kontrolu kvality výrobků manuálně, než se problém vyřeší, jelikož s návrhem nezanikne stávající pracoviště, neboť návrh slouží jako vylepšení, a ne kompletní přeměna pracoviště.

11 PŘÍNOSY PRÁCE

I když počáteční investice do zařízení bude vysoká, dlouhodobě může vést ke snížení nákladů díky rychlejšímu zpracování, menší chybovosti a snížení potřebě lidské práce.

11.1 Časová úspora

Po vytvoření databáze chyb a doladění algoritmů AI by pak samotný proces kontroly kvality pomocí umělé inteligence měl být významně rychlejší než současná lidská kontrola. Zatímco v současné kontrole se kontrolují jednotlivé body postupně, aby nedošlo k lidské chybě a možnému přehlédnutí nějakého z faktorů, umělá inteligence z návrhu by dělala kompletní kontrolu daného výrobku najednou s tím, že hrubý odhad doby pro provedení kontroly by se mohl pohybovat od 10 až 20 sekund na jeden kus včetně vygenerovaného reportu k danému výrobku, který už poté stačí jen vytisknout, tedy 84 až 92 % úspora času na jeden kus při finální kontrole. Počítá se s tím, že kontrolovaný výrobek má již potřebnou dokumentaci defektů v databázi.

Reporty generované systémem budou rozsáhlejší než současný formulář a systém časem může začít sám navrhopvat i potenciální oblasti pro zlepšení a zamezení chyb, které se objevují častěji.

11.2 Kvalita výrobků

Umělá inteligence při finální kontrole může poskytovat konzistentnější výsledky, protože není ovlivněna lidskými faktory, jako je únava nebo subjektivní posuzování výrobků. Umožní identifikovat problémy, které by mohly lidskému oku uniknout, jako jsou například malé nedostatky nebo anomálie materiálu. Využití strojového učení umožňuje výslednému zařízení se neustále učit z předchozích dat a každým dalším zkontrolovaným kusem být efektivnějším při kontrole kvality. AI může analyzovat sbíraná data pro identifikaci trendů a potenciálních problémů dříve, než se stanou součástí všech výrobků a umožní tak provádět preventivní opatření přímo ve výrobě, kde daný problém vzniká, což může vést k lepší celkové kvalitě produktů.

ZÁVĚR

Předmětem této bakalářské práce byla analýza využití umělé inteligence v oblasti kontroly kvality ve společnosti AGD PRINT s.r.o. Hlavním cílem bakalářské práce je dosažení časové úspory při finální kontrole kvality výrobků pomocí umělé inteligence.

Jednotlivé kapitoly v teoretické části se zaměřují na kvalitu a její kontrolu, umělou inteligenci a její propojení s kontrolou kvality.

V praktické části byla představena společnost AGD PRINT s.r.o., včetně základních informací, historie, nabízených výrobků a služeb. Bylo využito SWOT analýzy pro bližší seznámení se silnými a slabými stránkami včetně příležitostí a hrozeb, které ovlivňují společnost. Následně se práce zaměřuje na analýzu současného stavu celého procesu kontroly kvality a analýzu finální kontroly kvality vybraného výrobku a na základě téhle analýzy byl následně vyhotoven návrh na implementaci umělé inteligence pro finální kontrolu kvality.

Hlavním faktorem rozhodování, proč se zaměřit zrovna na finální kontrolu, byl fakt, že výroba ve společnosti funguje na principu High-Mix Low-Volume (vysoká variabilita, nízký objem) a implementovat umělou inteligenci přímo do výroby by bylo velice obtížné na správné nastavení z hlediska velkého množství proměnných, které by se musely nastavit, kdežto při finální kontrole kvality samotná implementace s sebou nenese takové množství překážek, kdy tou největší překážkou je vytvoření databáze chyb, která je klíčová pro správné fungování systému kontroly kvality.

V předposlední kapitole je ekonomické zhodnocení návrhu na zlepšení, které zahrnuje všechny potřebné komponenty včetně odhadu nákladů na samotné rozjetí návrhu.

Posledním krokem je zhodnocení navrhovaného řešení.

SEZNAM POUŽITÉ LITERATURY

ARINEZ, Jorge F.; CHANG, Qing; GAO, Robert X.; XU, Chengying a ZHANG, Jianjing, 2020. *Artificial Intelligence in Advanced Manufacturing: Current Status and Future Outlook*. Online. *ASME*. Roč. 142, č. 11, s. 16. Dostupné z: <https://asmedigitalcollection.asme.org/manufacturingscience/article/142/11/110804/1085487/Artificial-Intelligence-in-Advanced-Manufacturing>. [cit. 2024-05-01].

BANDYOPADHYAY, Hmrishav, 2022. *What Is Computer Vision? [Basic Tasks & Techniques]*. Online. V7 labs. Dostupné z: <https://www.v7labs.com/blog/what-is-computer-vision>. [cit. 2024-05-01].

BARTÁK, Roman, 2017. *Co je nového v umělé inteligenci*. CJN. Praha: Nová beseda. ISBN 978-80-906751-2-4.

GUPTA, N. a MANGLA, R., 2020. *Artificial intelligence basics: A self-teaching introduction*. Mercury Learning & Information. Virginia: Dulles: Mercury Learning And Information. ISBN 978-1-68392-516-3.

IMAI, Masaaki, 2005. *Gemba Kaizen*. Brno: Computer Press. ISBN 80-251-0850-3.

IMLER, Ken, 2008. *Strategické systémy kvality*. Pardubice: Radek Lévy. ISBN 978-80-904156-0-7.

KAPLAN, Jerry. *Artificial Intelligence: What Everyone Needs to Know*. New York: Oxford University Press, 2016. ISBN 978-0-19-060239-0.

Logo společnosti AGD PRINT s.r.o., 2009. Online. In: *Technické štítky, samolepky, etikety, reklamní předměty*. Dostupné z: <https://www.agdprint.cz/>. [cit. 2024-05-01].

MARR, Bernard a WARD, Matt, 2019. *Artificial intelligence in practice: How 50 successful companies used artificial intelligence to solve problems*. West Sussex, United Kingdom: John Wiley. ISBN 978-1-119-54898-0.

NAGYFI, Richard, 2018. *The differences between Artificial and Biological Neural Networks*. Online. In: *Towards Data Science*. Dostupné z: <https://towardsdatascience.com/the-differences-between-artificial-and-biological-neural-networks-a8b46db828b7>. [cit. 2024-05-01].

RAPP, Katie, 2022. *Artificial Intelligence in Manufacturing: Real World Success Stories and Lessons Learned*. Online. National Institute of Standards and Technology. Dostupné

z: <https://www.nist.gov/blogs/manufacturing-innovation-blog/artificial-intelligence-manufacturing-real-world-success-stories>. [cit. 2024-05-01].

RUSSELL, Stuart J. a NORVIG, Peter. *Artificial Intelligence: a Modern Approach*. Third edition. Boston: Pearson, 2016. ISBN 978-1-292-15396-4.

SRIVASTAVA, Sudeep, 2024. *How AI is Proving as a Game Changer in Manufacturing – Use Cases and Examples*. Online. Appinventiv. Dostupné z: <https://appinventiv.com/blog/ai-in-manufacturing/>. [cit. 2024-05-01].

SUCHÁNEK, Petr, 2011. *Kvalita jako faktor konkurenceschopnosti podniku*. Brno: Masarykova univerzita, Ekonomicko-správní fakulta. ISBN 978-80-210-5688-6.

SUNDARAM, Sarvesh a ZEID, Abe, 2023. *Artificial Intelligence-Based Smart Quality Inspection for Manufacturing*. Online. *Micromachines*. Roč. 14, č. 3, s. 19. Dostupné z: <https://www.mdpi.com/2072-666X/14/3/570>. [cit. 2024-05-01].

SVOZILOVÁ, Alena, 2011. *Zlepšování podnikových procesů*. Praha: Grada. ISBN 978-80-247-3938-0.

SVOZILOVÁ, Alena, 2016. *Projektový management: Systémový přístup k řízení projektů*. 3., aktualizované a rozšířené vydání. Expert. Praha: Grada. ISBN 978-80-271-0075-0.

SZELISKI, Richard. *Computer Vision: Algorithms and Applications*. Second edition. Cham: Springer, 2022. ISBN 978-3-030-34371-2

UCAR, Aysegul; KARAKOSE, Mehmet a KIRIMÇA, Necim, 2024. *Artificial Intelligence for Predictive Maintenance Applications: Key Components, Trustworthiness, and Future Trends*. Online. *Applied Sciences*. Roč. 14, č. 2, s. 40. Dostupné z: <https://www.mdpi.com/2076-3417/14/2/898>. [cit. 2024-05-01].

ZELINKA, Ivan, 2003. *Umělá inteligence: hrozba nebo naděje?* Praha: BEN – technická literatura. ISBN 80-7300-068-7.

SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK

- AI Artificial intelligence (umělá inteligence)
- CNN Convolutional Neural Network (Konvoluční neuronová síť)
- CPU Central Processing Unit (Procesor)
- DoE Design of Experiments (Design experimentů)
- DPH Daň z přidané hodnoty
- EU Evropská Unie
- FMEA Failure Mode and Effects Analysis (Analýza možného výskytu a vlivu vad)
- GPU Graphics Processing Unit (Grafická karta)
- IT Informační technologie
- Kč Koruna česká
- QC Quality Control (Kontrola kvality)
- QFD Quality Function Deployment (Nepřekládá se)
- RUL Remaining Useful Life (Zbývající užitečná životnost)
- SQI Smart Quality Inspection (Chytrá kontrola kvality)

SEZNAM OBRÁZKŮ

Obrázek 1 Klíčové součásti prediktivní údržby založené na umělé inteligenci	20
Obrázek 2 Metodologie SQI	22
Obrázek 3 Biologický neuron a umělý neuron	23
Obrázek 4 Klasický program vs strojové učení	25
Obrázek 5 Logo společnosti AGD PRINT s.r.o	30
Obrázek 6 Organizační struktura společnosti	31
Obrázek 7 Formulář výstupní kontroly	42
Obrázek 8 Vývojový diagram návrhu implementace	46
Obrázek 9 Ukázka anotace	47
Obrázek 10 3D ilustrační model konstrukce	53

SEZNAM TABULEK

Tabulka 1 Swot analýza.....	36
Tabulka 2 Doba měřené finální kontroly.....	44
Tabulka 3 Náklady na rozjetí návrhu.....	54
Tabulka 4 Náklady na pořízení hardwaru potřebného hardwaru.....	54
Tabulka 5 Náklady na materiál potřebný na konstrukci.....	55

SEZNAM PŘÍLOH

Příloha P I: Vývojový diagram finální kontroly štitku XYZ

PŘÍLOHA P I: VÝVOJOVÝ DIAGRAM FINÁLNÍ KONTROLY ŠTÍTKU XYZ

