



УНИВЕРЗИТЕТ У КРАГУЈЕВЦУ
ФАКУЛТЕТ ИНЖЕЊЕРСКИХ НАУКА

Немања З. Пајић

**РАЗВОЈ МОДЕЛА ЗА УПРАВЉАЊЕ
ПРОЦЕСОМ ИСПИТИВАЊА КВАЛИТЕТА
У LEAN ИНДУСТРИЈСКИМ
СИСТЕМИМА БАЗИРАНОГ НА
МЕТОДАМА ВЕШТАЧКЕ
ИНТЕЛИГЕНЦИЈЕ**

докторска дисертација

Крагујевац, 2024



UNIVERSITY OF KRAGUJEVAC
FACULTY OF ENGINEERING

Nemanja Z. Pajić

**DEVELOPMENT OF A MODEL FOR
MANAGEMENT OF THE QUALITY
TESTING PROCESS IN LEAN INDUSTRIAL
SYSTEMS BASED ON ARTIFICIAL
INTELLIGENCE METHODS**

Doctoral Dissertation

Kragujevac, 2024

Аутор
Име и презиме: Немања Пајић
Датум и место рођења: 20.12.1990.
Садашње запослење: „ZF Group“ - Дивизиони експерт за нове технологије у домену квалитета (Дивизија електричних возила)
Докторска дисертација
Наслов: РАЗВОЈ МОДЕЛА ЗА УПРАВЉАЊЕ ПРОЦЕСОМ ИСПИТИВАЊА КВАЛИТЕТА У LEAN ИНДУСТРИЈСКИМ СИСТЕМИМА БАЗИРАНОГ НА МЕТОДАМА ВЕШТАЧКЕ ИНТЕЛИГЕНЦИЈЕ
Број страница: 142
Број слика: 40
Број библиографских података: 206
Установа и место где је рад израђен: Факултет инжењерских наука Универзитета у Крагујевцу
Научна област (УДК): Машинско инжењерство;
Ментор: др Александар Ђорђевић, ванредни професор, Факултет инжењерских наука Универзитета у Крагујевцу
Оцена и одбрана
Датум пријаве теме: 05.09.2022.
Број одлуке и датум прихватања теме докторске/уметничке дисертације:
Број: IV -04-7/10 Датум: 24.01.2024.

Апстракт

Ова дисертација истражује примену метода вештачке интелигенције у области контроле квалитета у оквиру Индустријске револуције 4.0. Овај рад се бави предвиђањем исхода операције лемљења помоћу машинског учења, као и применом машинског вида за класификацију и детекцију дефеката при наливању лепка у аутомобилској индустрији кроз две студије случаја. Такође је приказан идејни концепт евалуације купчевих захтева помоћу вештачке интелигенције, као и обезбеђење квалитета ласерски заварених спојева. Приказом коришћења различитих алгоритама и метода вештачке интелигенције, ова дисертација представља приказ примене напредних приступа контроле квалитета у производним системима. У раду је доказано да аутоматска класификација и детекција дефекта доприноси ефикасности и смањењу грешака у производним процесима, као и да смањује трошкове тестирања. Исто тако, примена вештачке интелигенције у обезбеђењу квалитета различитих процеса омогућава бржу и ефикаснију процедуру анализе дефеката и управљања квалитетом. Кроз сложен приступ истраживању, ова дисертација има за циљ да допринесе напретку у области контроле квалитета у индустријским окружењима, смањењу трошкова и времена, као и побољшању стандарда квалитета у оквиру индустрије 4.0. Као резултат овог истраживања, представљени су нови резултати и савремене методе које би могле значајно утицати на будући развој у области контроле квалитета у индустријском окружењу.

Кључне речи: *Вештачка интелигенција, Контрола квалитета, Индустрија 4.0, Машински вид, Машинско учење, Класификација дефекта, Детекција дефеката, Аутомобилска индустрија*

Abstract

This dissertation explores the application of artificial intelligence methods in the field of quality control within the framework of Industry 4.0. The study focuses on predicting the outcome of soldering operations using machine learning, as well as applying machine vision for defect classification and detection during adhesive pouring operations in the automotive industry through two case studies. Additionally, it presents the conceptual concept of evaluating customer requirements using artificial intelligence, as well as ensuring the quality of laser-welded joints. By employing various algorithms and methods of artificial intelligence, this dissertation demonstrates the application of advanced quality control approaches in production systems. The research proves that automatic defect classification and detection contribute to efficiency and error reduction in manufacturing processes, as well as cost savings in testing. Similarly, the application of artificial intelligence in ensuring the quality of various processes enables a faster and more efficient procedure for defect analysis and quality management. Through a comprehensive research approach, this dissertation aims to contribute to advancements in quality control within industrial environments, reducing costs and time, and enhancing quality standards within Industry 4.0. As a result of this research, new findings and contemporary methods are presented that could significantly impact future developments in the field of quality control in industrial settings.

Keywords: *Artificial Intelligence, Quality Control, Industry 4.0, Machine Vision, Machine Learning, Defect Classification, Defect Detection, Automotive Industry*

Садржај

1	УВОД	1
1.1	Предмет и циљ истраживања	1
1.2	Основне хипотезе	2
1.3	Методе истраживања	2
1.4	Преглед садржаја дисертације	3
2	Преглед литературе у подручју Индустрије 4.0 са фокусом на напредне технологије недеструктивног типа у области контроле квалитета	5
2.1	<i>Lean</i> принципи и филозофија	5
2.2	Управљање квалитетом у <i>Lean</i> окружењу	6
2.3	Теоријске основе концепта Индустрије 4.0 и примена у области управљања квалитетом	7
2.4	Напредне технологије недеструктивног типа у области контроле квалитета	22
3	Преглед литературе у подручју примене вештачке интелигенције у индустријском окружењу са фокусом на област контроле квалитета	33
3.1	Различите примене вештачке интелигенције у индустрији	35
3.2	Примена вештачке интелигенције у контроли квалитета	41
3.3	Практични примери примене вештачке интелигенције	46
3.4	Примери метода и алгоритама машинског учења погодних за мале скупове података	53
4	Развој и имплементација система за контролу квалитета у индустрији 4.0 у <i>Lean</i> индустријском окружењу, уз примену вештачке интелигенције	57
4.1	Примена модела машинског учења на мале скупове података за предвиђање исхода процеса лемљења у аутомобилској индустрији	59
4.1.1	Разматрања студије случаја	59
4.1.2	Опис процеса лемљења и деструктивног тестирања залемљених спојева	60
4.1.3	Садржај студија случаја и недостаци литературе	63
4.1.4	Материјали и методе	63
4.1.5	Прикупљање и обележавање података	64
4.1.5.1	Припрема података	65
4.1.5.2	Ограничења података	65
4.1.6	Преглед разматраних метода машинског учења	66
4.1.7	Оптимизација хипер параметара и одабир карактеристика	67
4.1.8	Резултати примене модела машинског учења и дискусија	68
4.1.8.1	Корелациона анализа	68
4.1.8.2	Резултати регресионог модела	71
4.1.9	Предности приступа предвиђања квалитета помоћу машинског учења	75
4.1.10	Разматрања студије случаја	76

4.2	Примена машинског вида за класификацију и детекцију дефеката при наливању лепка за процесе спајања у аутомобилској индустрији	79
4.2.1	Уводна разматрања студије случаја	79
4.2.2	Анализа проблема	81
4.2.3	Скуп података	82
4.2.4	Први ниво: Класификација слика	83
4.2.4.1	Развој и тренирање модела	84
4.2.4.2	Тестирање и евалуација модела	85
4.2.5	Други ниво: Детекција објеката	86
4.2.5.1	Претпроцесирање и аотирање слика	87
4.2.5.2	Развој и тренирање модела	88
4.2.5.3	Тестирање и евалуација модела	89
4.2.6	Разматрања студије случаја	95
4.3	Потенцијали примене вештачке интелигенције у евалуацији купчевих захтева у аутомобилској индустрији	97
4.3.1	Евалуација захтева купаца у аутомобилској индустрији	98
4.3.2	Индустријска револуција 4.0 у оквиру евалуације захтева купаца у аутомобилској индустрији	102
4.3.3	Разматрања на основу извршене студије случаја	104
4.4	Могућности примене вештачке интелигенције у обезбеђењу квалитета ласерски заварених спојева	106
4.4.1	Уводна разматрања студије случаја	106
4.4.2	Примена вештачке интелигенције у контроли квалитета ласерски заварених спојева	107
4.4.3	Конвенционалне методе контроле квалитета ласерског заваривања	107
4.4.4	Систем паметног осигурања квалитета у процесу ласерског заваривања	108
4.4.4.1	Технике надзора сигнала процесних сензора праћених помоћу вештачке интелигенције код ласерског заваривања	109
4.4.4.2	Технике надзора процеса ласерског заваривања	110
4.4.5	Успешни примери и могућности примене вештачке интелигенције у осигурању квалитета ласерског заваривања	111
4.4.6	Разматрања студије случаја	112
	Закључак	114
	Литература	119
	Прилог	132

1 УВОД

У временима брзог развоја технологије, примена вештачке интелигенције у контроли квалитета постала један од најзначајнијих аспеката у индустријским окружењима. Испитивање квалитета производа и предвиђање могућих дефеката постало је од кључног значаја за компаније које желе да поједноставе и сниже трошкове својих производних процесе. Деструктивни тестови, који су досад били коришћени за проверу квалитета, могу бити скупи и временски захтевни. Коришћењем вештачке интелигенције, компаније могу предвидети и детектовати дефекте у раној фази производње, чиме се избегавају додатни трошкови и временски губици.

Lean индустријски системи представљају филозофију и методологију управљања производњом и процесима који имају за циљ максимално уклањање губитака и ефикасно коришћење ресурса. Главни циљ *Lean* система је да се идентификују и уклоне све врсте отпада, од непотребних процеса до неефикасне употребе ресурса. Ово обухвата све операције које не додају вредност производу или услузи, као што су чекање, прекомерна производња, недостаци у квалитету, непотребно кретање и недостаци у складиштењу.

Ова докторска дисертација приказује развој модела за управљање процесом испитивања квалитета у *Lean* индустријским системима заснованим на методама вештачке интелигенције. Фокус рада је на унапређењу и примени савремених технологија за контролу квалитета заснованих на примени вештачке интелигенције, односно машинског учења. Сврха ове дисертације је креирање модела за контролу квалитета, недеструктивног типа, у *Lean* индустријском окружењу, који се може имплементирати у оквиру постојећих индустријских постројења. Остали циљеви су развој система, спречавање губитака у оквиру производње и тестирања, унапређење укупне ефикасности система и дигитализација процеса управљања квалитетом у оквиру замене неефикасних тестова.

1.1 Предмет и циљ истраживања

Ова дисертација истражује примену вештачке интелигенције у контроли квалитета, фокусирајући се на *Lean* индустријске системе. Примарни циљ рада је да се развије и оптимизује модел машинског учења који ће са великом прецизношћу предвидети квалитет производа без потребе за деструктивним тестовима. Коришћењем различитих метода машинског учења и алгоритама, истраживачи у овој области нашли су ефикасне начине за предвиђање исхода производних процеса.

У оквиру дисертације, такође ће бити истражене и друге напредне технологије недеструктивног типа, као и њихова примена у контроли квалитета. Испитивање материјала помоћу рендгенских зрака, вртложних струја и других метода имају значајан потенцијал за откривање дефеката и прецизно оцењивање квалитета производа.

Кроз обухватање различитих аспеката примене вештачке интелигенције у контроли квалитета, ова дисертација има за циљ да допринесе напретку у индустријским производним процесима и унапреди квалитет производа на путу ка индустрији 4.0.

У оквиру ове дисертације, истраживање ће бити настављено практичном применом вештачке интелигенције у индустријском окружењу, у реалним пројектима и кроз анализе потенцијала за одређене намене. Различите примене вештачке интелигенције у индустрији 4.0, укључујући машинско учење, дубоко учење, машински вид и друге технике, пружају широк спектар могућности за оптимизацију производних процеса и контролу квалитета. Заменом конвенционалних метода испитивања квалитета методама вештачке интелигенције могуће је значајно смањити трошкове тестирања,

убрзати процес рада, повећати учесталост тестирања, произвести детаљније извештаје о испитивању квалитета.

У оквиру ове дисертације ће бити размотрена примена алгоритама машинског учења за предвиђања исхода операције лемљења бакарних намотаја на фазни прстен статора електромотора и примена машинског вида за класификацију и детекцију дефеката при наливању лепка за процесе спајања у аутомобилској индустрији. Уз примену модерних алгоритама и метода машинског учења, циљ је развити систем који ће аутоматски класификовати и детектовати дефекте, чиме ће се смањити могућност грешке у производним процесима и повећати квалитет производа. Додатно, истраживање ће обухвати дискусију о потенцијалној примени вештачке интелигенције у евалуацији купчевих захтева у аутомобилској индустрији. Уз помоћ модерних технологија и метода, купчеви захтеви могу бити ефикасније и брже евалуирани. Такође је размотрен потенцијал имплементације паметних решења заснованих на вештачкој интелигенцији у обезбеђењу квалитета ласерски заварених спојева.

Кроз разнолик приступ примени вештачке интелигенције у контроли квалитета, ова дисертација има за циљ да допринесе напретку у индустријским окружењима и доведе до оптимизације производних процеса и подизања стандарда квалитета у оквиру индустрије 4.0.

Практични резултат истраживања је развој поузданих, ефикасних (финансијски и временски), 100% линијских, недеструктивних, метода контроле квалитета за примену у *Lean* индустријском окружењу. Развој решења које ће бити безбедно, ефикасно, ефективно, поуздано, брзо имплементирано са малим улагањем и кратким периодом поврата инвестиције.

1.2 Основне хипотезе

Основне хипотезе докторске дисертације од којих се пошло на основу постављеног циља истраживања, досадашњих истраживачких активности кандидата и резултата других аутора у подручју истраживања, састоје се од следећих претпоставки:

- (X_1) Може се развити напредни систем за контролу квалитета применом напредних технологија попут вештачке интелигенције у *Lean* индустријском окружењу, који резултира бољим перформансама.
- (X_2) Примена напредног система за контролу квалитета недеструктивног типа заснованог на примени вештачке интелигенције потенцијално може довести до повећања ефикасности и ефективности процеса контроле квалитета, кроз уштеде у процесу тестирања, скраћењем трајања тестова, пружањем бољег увида у квалитет производа или процеса, и унапређењем безбедности и здравља запослених.
- (X_3) Могуће је анулирати постојеће вишеструке препреке и отежавајуће околности за имплементацију напредног система за контролу квалитета недеструктивног типа заснованог на примени вештачке интелигенције у *Lean* индустријском окружењу у средњим и великим предузећима.

1.3 Методе истраживања

Истраживања планирана у оквиру докторске дисертације биће теоријска и експериментална. Теоријски део истраживања ће се заснивати на прегледу литературе у области недеструктивних метода тестирања (НДТ) односно испитивања без разарања (ИБР) и критичког расуђивања о примењивости одређених метода на конкретни

пројектни задатак. Други део теоријског истраживања ће се заснивати на прегледу литературе у области примене вештачке интелигенције, специфично алгоритама машинског учења, у замени или допуни тестова квалитета, али и у индустрији генерално.

Методе засноване на контроли квалитета ће бити примењене у поступку дефинисања захтева за систем/апликацију која се развија како би се у раној фази предвидели захтеви и ограничења у која се решење мора уклопити. На тај начин се обезбеђује да решење буде ефикасно, ефективно, једноставно за интеграцију у савремене системе за управљање квалитетом, и у складу са највишим захтевима стандарда квалитета.

Методе машинског учења ће бити примењене за развој алгоритма који би могао на основу историјских података процесних праметара и резултата деструктивних тестова предвидети исход производних процеса односно резултате које би производ остварио на деструктивном тесту. На тај начин би деструктивно тестирање постало непотребно те би се могле остварити значајне уштеде.

Такође ће методе машинског учења бити примењене у решавању проблема детекције дефеката насталих приликом наливања лепка за процесе спајања елемената у поризводној индустрији. Кроз експериментални приступ ће бити приказан процес интеграције једног оваквог решења, потенцијалне препреке и ограничења овог приступа.

Експерименталне методе ће се заснивати на имплементацији развијеног решења у производни и контролни процес, и документовање свих запажања. Запажања у смислу потешкоћа при прикупљању података, интеграцији решења у недигитализоване процесе, неопходним модификацијама производног процеса, и процеса управљања квалитетом.

1.4 Преглед садржаја дисертације

План израде дисертације је направљен на основу досадашњих искустава, истраживачких активности као и анализе постојеће научне литературе.

Оквирни садржај рада:

1. Уводна разматрања
2. Преглед литературе у подручју напредних технологија недеструктивног типа у области контроле квалитета
3. Преглед литературе у подручју примене вештачке интелигенције, односно машинског учења, у области контроле квалитета
4. Развој система за контролу квалитета у индустрији 4.0 у *Lean* индустријском окружењу, уз примену машинског учења
5. Имплементација система заснованог на машинском учењу
6. Закључци
7. Литература

• Увод

У овом поглављу биће дат предмет, циљ рада, полазне хипотезе и очекивани допринос докторске дисертације као и кратак преглед структуре.

• Преглед литературе у подручју Индустрије 4.0 са фокусом на напредне технологије недеструктивног типа у области контроле квалитета

У оквиру овог поглавља презентоваће се стање и отворена истраживачка питања у области контроле квалитета и ИБР у индустрији 4.0 у *Lean* индустријском окружењу. Предности и мане одређених технологија, односно метода тестирања, на конкретном пројектном примеру.

• Преглед литературе у подручју примене вештачке интелигенције у индустријском окружењу са фокусом на област контроле квалитета

У оквиру овог поглавља презентоваће се стање и отворена истраживачка питања у области примене вештачке интелигенције, односно машинског учења у индустрији 4.0 у *Lean* индустријском окружењу у различитим секторима са фокусом на тестове контроле квалитета. Биће приказани и потенцијални бенефити од употребе вештачке интелигенције као самосталне методе или упарене са неком од других напредних технологија.

- **Развој и имплементација система за контролу квалитета у индустрији 4.0 у *Lean* индустријском окружењу, уз примену вештачке интелигенције**

У оквиру овог поглавља биће представљен развој система за контролу квалитета залемљених спојева, као и процеса наливања лепка за потребе спајања елемената у производној индустрији уз примену савремених технологија које чине основне стубове индустрије 4.0. Развијени систем за контролу квалитета биће примењен на реалном систему у циљу анализе перформанси развијеног решења. Потребно је установити у којој мери је решење примењиво и поуздано. Такође је дата и анализа потенцијала примене вештачке интелигенције у евалуацији захтева купаца као и обезбеђења квалитета ласерски заварених спојеве.

- **Закључак**

У овом поглављу ће бити представљен доказ хипотеза, односно потврдиће се да је остварен циљ истраживања. Такође биће презентовани теоријски и практични доприноси докторске дисертације, ограничења и правци даљег истраживања.

- **Литература**

Овај део ће обухватити све литературне наводе који су коришћени у току израде ове докторске дисертације.

2 Преглед литературе у подручју Индустрије 4.0 са фокусом на напредне технологије недеструктивног типа у области контроле квалитета

Темељи развоја индустрије, па и сваке њене револуције, су највећим делом били технологија и наука. Све индустријске револуције су везиване за примену нових технологија, коришћење нових извора енергије и нових средстава транспорта. Тешко је повући јасну линију између различитих индустријских револуција и одредити тачан тренутак настанка одређених револуција. Оне су биле условљене стањем привреде, технологије и геополитичким дешавањима. Током година, разне врсте технологија су се усавршавале од којих неке и данас користимо док смо друге заменили напреднијим решењима (Charron et al., 2015).

2.1 *Lean* принципи и филозофија

Lean (Лин) представља методологију управљања и филозофију која се фокусира на елиминацију отпада и постизање високог нивоа ефикасности и квалитета у производним и пословним процесима. Ова концепција потиче из Тојотиног производног система и обухвата различите принципе, алатке и технике које се користе за унапређење рада организација (Charron et al., 2015). Циљ *Lean* методологије је подстицање максималне вредности за купце са минималним отпадом у свим аспектима пословања.

Основни принципи *Lean* методологије обухватају (Bertagnolli, 2022):

1. **Идентификација вредности:** Препознавање вредности из перспективе купца. Ово укључује разумевање потреба и жеља купца и фокусирање на испоруку производа или услуга који задовољавају те потребе.
2. **Мапирање тока вредности:** Анализа и мапирање целокупног тока вредности, што обухвата све активности потребне за довођење производа или услуге од развоја до испоруке. Ово помаже у идентификовању отпада и могућности за унапређење.
3. **Креирање тока:** Усмеравање процеса како би се обезбедио гладак и континуиран ток рада без прекида, кашњења или уских грла. Ово укључује организовање радних токова тако да се минимизира време чекања и преласка између различитих фаза производње или испоруке услуга.
4. **Имплементација система повлачења:** Увођење система повлачења где је рад заснован на стварној потреби (потражњи, односно поручбини) купца, а не на основу прогноза или производних распореда. Ово помаже у спречавању прекомерне производње и смањује нивое инвентара, складиштених производа.
5. **Стремљење ка савршенству:** Промовисање културе континуалног унапређења и тежње ка савршенству у свим аспектима операција. Подстицање запослених на свим нивоима да идентификују могућности за унапређење и спроводе промене како би се постигли виши нивои ефикасности, квалитета и задовољства купаца.
6. **Поштовање људи:** Препознавање важности омогућавања и укључивања запослених. Поштовање људи подразумева стварање подржавајућег радног окружења где се запослени подстичу да доприносе идејама, развијају своје вештине и преузимају одговорност за свој рад.
7. **Елиминација отпада:** Идентификација и уклањање отпада у свим његовим облицима, укључујући превише производње, времена чекања, непотребног транспорта, вишак инвентара, прераду, дефекте и неискоришћен таленат или ресурсе.

Ови принципи служе као водила у *Lean* методологији и усмеравају организације у њиховим напорима да оптимизују процесе, смање трошкове, побољшају квалитет и унапреде задовољство купаца (Bertagnolli, 2022).

У *Lean* методологији, врсте отпада се односе на било коју активност или процес који троши ресурсе, али не додаје вредност купцу или финалном производу. Постоји неколико препознатих врста отпада у *Lean* принципима (Charron et al., 2015):

1. **Транспорт:** Непотребно кретање материјала или производа између процеса или локација, што може довести до кашњења, оштећења и додатних трошкова.

2. **Инвентар:** Складиштења материјала, полупроизвода или готових производа преко онога што је тренутно потребно. То доводи до замрзавања капитала и заузимања простора, као и могућности истека рока одређених производа .

3. **Покрет:** Непотребна кретања људи или опреме унутар производног процеса, што може трошити време, енергију и ресурсе.

4. **Чекање:** Време неактивности или кашњења између корака у производњи због неефикасности, кварова или уских грла, што доводи до смањене производње и повећања времена обраде.

5. **Прекомерна производња:** Прекомерна производња робе или услуга, више него што тренутно купци потражују, што резултује вишком ускладиштених производа, повећаним трошковима и могућим проблемима са квалитетом.

6. **Прекомерна обрада:** Извођење непотребних или сувишних корака у производном процесу који не додају вредност финалном производу, што доводи до губљења времена, труда и ресурса.

7. **Дефекти:** Грешке, дефекти или недостаци у производима или услугама који захтевају додатни рад, поправку или одбацивање, што доводи до повећаних трошкова, незадовољства купаца и могућег губитка репутације.

8. **Људски потенцијал:** Губици услед недовољног искоришћења људског потенцијала, у смислу: талента, вештина, знања, и потенцијалних увида запослених.

Ових осам врста губитака често се идентификују у *Lean* методологијама, а минимизирање или елиминисање је кључно за побољшање ефикасности, квалитета и задовољства купаца у производним и услужним индустријским областима.

2.2 Управљање квалитетом у *Lean* окружењу

Управљање тоталним квалитетом (TQM – енг. *Total Quality management*) представља комплексан приступ управљању квалитетом производа, процеса и услуга унутар организације. Ово је управљачка филозофија која тежи да изгради менталитет континуалног унапређења на свим нивоима и сегментима организације (Vasou et al., 2018). Основни принцип који стоји иза TQM-а јесте задовољавање и превазилажење очекивања купца испоруком производа и услуга највишег квалитета.

TQM потиче из 1950-их година, а добио је на значају осамдесетих и деведесетих година прошлог века када су организације препознале значај квалитета у постизању дугорочног успеха и конкурентности. TQM није само скуп алатки или техника, већ културна промена која укључује сваког члана организације у потрази за изврсношћу (Clark et al., 2013). Кључни елементи Управљања тоталним квалитетом укључују (Blecken et al., 2010):

1. **Фокус на купца:** TQM посебан акценат ставља на разумевање и испуњавање потреба и очекивања купаца. Организације које примењују TQM

настоје да креирају производе и услуге који пружају вредност и задовољство њиховим купцима.

2. **Континуална унапређења:** TQM се заснива на уверењу да увек има места за унапређење. Подстиче организације да постојано оцењују и унапређују своје процесе, производе и услуге како би постигле више нивое квалитета и ефикасности.

3. **Укљученост запослених:** TQM препознаје значај укључивања запослених на свим нивоима у процес унапређења квалитета. Запослени који су укључени и оснажени склонији су да допринесу иновативним идејама и да преузму одговорност за квалитет свог рада.

4. **Процесни приступ:** TQM заступа приступ оријентисан на процесе у управљању операцијама. Фокусирање на целокупни процес, од улаза до излаза, омогућава организацијама да идентификују и уклоне узроке варијабилности и отпада.

5. **Одлуке засноване на подацима:** TQM се ослања на податке и статистичке методе за доношење одлука. Организације скупљају и анализирају податке како би идентификовале трендове, донеле информисане одлуке и пратиле ефикасност напора за унапређење.

6. **Ангажованост лидера:** Успешна имплементација TQM захтева јаку ангажованост лидерства. Лидери играју кључну улогу у постављању визије, усмеравању ка култури оријентисаној на квалитет и обезбеђивању неопходних ресурса за TQM иницијативе.

7. **Односи са добављачима:** TQM се шири и на односе са добављачима. Колаборативна и међусобно корисна партнерства са добављачима наглашавају се како би се обезбедио квалитет улазних ресурса у процесе организације.

Управљање тоталним квалитетом није приступ који се може копирати са једног система на други, већ се мора прилагодити специфичним потребама и контексту сваке организације. Када се интегрише са *Lean* принципима, TQM доприноси стварању културе постојаног унапређења и изврности, у складу са општим циљевима *Lean* методологија у побољшању ефикасности, смањењу отпада и испоруци вредности купцима (Vasour et al., 2018).

2.3 Теоријске основе концепта Индустрије 4.0 и примена у области управљања квалитетом

Индустрија 4.0 доноси многе новине у разним областима. Не мислећи само на нове технологије, јер многи технолошки стубови четврте индустријске револуције су присутни 50 и више година. За ефикасну и ефективну примену неких технологија је било потребно усавршавање и унапређење саме технологије, попут 3Д штампе. За неке технологије је било потребно развити инфраструктуру, нпр. повећање броја корисника паметних уређаја и развој бежичне мреже за примену интернета ствари, док су неке технологије биле условљене процесорским капацитетима, који се сваке две године дуплирају (Calisir and Camgoz Akdag, 2018). Индустрија 4.0 доноси револуцију разним процесима, од управљања производњом, контроле квалитета, управљања пројектима до процене ризика. Обзиром да је ова револуција у одређеном контексту још увек у зачетку, а технологија се развија брже него икада пре, могу се очекивати многа нова решења у разним областима (Fathi et al., 2019).

Индустрија 4.0 представља концепт нове ере у производњи и производним процесима. Она обухвата употребу најновијих информатичких и комуникационих

технологија, како би се постигла висока интеграција у целокупном систему (Fathi et al., 2019). Ова промена представља револуцију у начину на који се производе роба и услуге, и доноси нове могућности и ризике.

Додатно, велика улога у Индустрији 4.0 припада вештачкој интелигенцији и машинском учењу (Azizi, 2019). Алгоритми и модели машинског учења омогућавају аутоматску анализу података и доношење интелигентних одлука. Интелигентни системи могу самостално препознати обрасце и тенденције, предвидети проблематичне ситуације и предложити ефикасна решења (Shukla et al., 2019). Ово доприноси повећању ефикасности, смањењу грешака и оптималном искоришћењу ресурса.

Централни концепт у Индустрији 4.0 је фабрика која се сама организује (енг. *smart factory*) (Azizi, 2019). Машине, роботи и системи за контролу производње су повезани и комуницирају међусобно. Подаци се размењују без потребе за људском интервенцијом и системи могу динамички прилагођавати своје радње у складу са условима и захтевима производње. Ово омогућава флексибилност и могућност промене производње са минималним временом прекида.

Индустрија 4.0 има потенцијал да трансформише производњу и донесе брзе и сигурне иновације. Она ствара нове начине за унапређење ефикасности, квалитета и капацитета производње. Ипак, уз нове могућности, она доноси и нове ризике као што су сигурност података, заштита приватности и навикавање радне снаге на нове технологије. Укључивање Индустрије 4.0 захтева стратегију, инвестиције и обуку како би се максимално искористиле предности које она пружа.

Четврта индустријска револуција као и све пре ње се не везује за једну појаву већ за скуп открића, дешавања и унапређења. Четврта индустријска револуција је заправо дигитализација процеса, било производних, менаџерских или административних. Основни принципи на којима се индустрија 4.0 заснива су (Nauyar and Kumar, 2020):

- међусобна повезаност,
- транспарентност информација,
- техничка подршка и,
- децентрализовано одлучивање.

Међусобна повезаност се односи на повезаност производних машина, мерне опреме, сензора, система подршке са паметним направама и рачунарским системима (Nauyar and Kumar, 2020). На овај начин се прикупљене информације софтверски обрађују и обезбеђују корисницима система обрађену, једноставну, правовремену и прецизну информацију (Gunal, 2019). Овим приступом се олакшава доношење одлуке и правовремено реаговање на промене у процесу. На пример, ако се при управљању одржавањем у аутомобилској индустрији прати број застоја у производњи услед отказа опреме као један од кључних индикатора, путем различитих сајбер-физичких система се тај параметар може пратити и слати у информатички систем. Инжењер може увидом у информатички систем у реалном времену видети застоје на линији, историју застоја за претходни период, чак и део опреме који је отказао.

Међусобна повезаност и интеграција у Индустрији 4.0 омогућавају боље управљање и надзор над производним процесима. Прикупљени подаци о раду машина, стању опреме и процесима се аутоматски преносе и обрађују у реалном времену. Ова информација је доступна инжењерима и менаџерима који могу донети брзе и правилне одлуке у вези са производњом. Интелигентни системи и алгоритми машинског учења користе прикупљене податке за анализу и предвиђање. На основу историјских података и образаца, системи могу детектовати аномалије, предвидети могуће проблеме и понудити начин за њихово решавање (Gunal, 2019). На пример, ако систем примети необичан температурни сигнал са неке машине, може генерисати упозорење и

предложити одређене кораке за поправку или одржавање. Ова нова ера производње такође омогућава примену предиктивног одржавања (енг. *predictive maintenance*) у којем се на основу података и њихове анализе предвиђати могући проблеми и упозоравати на потенцијалне отказе опреме. Ово ефикасно коришћење информација и ресурса смањује време заустављања производње и оптимизује рад опреме. Уз сталну комуникацију и размену информација између система и уређаја, компаније у Индустрији 4.0 могу имати бољи увид у своје процесе и ресурсе (Nayyar and Kumar, 2020). Путем визуелизације података и управљања нивоима производње, менаџери могу пратити напредак, идентификовати потенцијалне проблеме и унапредити ефикасност. Са додатним развојем вештачке интелигенције и аналитике података, Индустрија 4.0 нуди огроман потенцијал за унапређење квалитета и контроле квалитета у производњи. Путем аутоматизоване анализе података и коришћења модела машинског учења, компаније могу брже и ефикасније откривати дефекте и проблеме у производњи, смањити број неисправних делова и побољшати квалитет производа. Ова технологија је од суштинске важности за постизање конкурентности и успешности у модерној индустрији.

Транспарентност информација се односи на доступност информација у централној бази података (Azizi, 2019). На пример, инжењер службе одржавања ће моћи у реалном времену да одговори на застој и тако смањи губитке услед истог. Службеник набавке ће имати увид у делове који најчешће отказују па ће моћи прецизније испланирати залиху резервних делова и њихово поручивање. Инжењер квалитета ће имати податке о најчесталијим застојима на основу којих ће моћи да се посвети анализи њиховог корена узрока. Планер производње ће моћи да одреди реалне производне капацитете при изради плана. Сви ови процеси су се до сада најчешће заснивали на спором преносу информација и губљењу времена при тражењу правог извора информација.

У контексту Индустрије 4.0, транспарентност информација се значајно повећава и омогућава боље управљање и доношење одлука на основу доступних података. Кроз синхронизацију и употребу централне базе података, сви релевантни делови организације имају приступ информацијама које им требају у реалном времену. Транспарентност информација омогућава боље планирање и оптимизацију ресурса. Уз транспарентност информација, организација може постићи и већу ефикасност и квалитет у својим процесима. Преко бољег увида у радне параметре, менаџери могу идентификовати подручја у којима је потребно унапредити производни процес, боље тренирати запослене и имплементирати мере квалитета. Интеграција информација омогућава и прецизнију анализу корена проблема и управљање ризицима. Повећана транспарентност информација има и додатни утицај на однос са купцима. Преко бољег праћења стања производње и квалитета, компанија може пружити детаљније информације и имати отворенију комуникацију са својим купцима, што доприноси поверењу и повећава задовољство купаца.

Укратко, транспарентност информација у Индустрији 4.0 пружа значајне предности у планирању, управљању и контроли квалитета (Nayyar and Kumar, 2020). Информације су лако доступне и обрађују се у реалном времену, што омогућава брзе и правилне одлуке, оптимизацију процеса и повећање ефикасности.

Техничка подршка се огледа у подршци људима при обављању дела посла који је некада припадао људским ресурсима (Nayyar and Kumar, 2020). Системи могу, на пример, прикупити све податке о мерењу неког параметра путем сензора или друге опреме и самостално генерисати извештај квалитета (Pascual et al., 2020). Овим се елиминише потреба да човек који припрема извештај буде стручан у изради табела, у на пример *Microsoft Excel* програму, као и за његовим ангажовањем на том задатку. Уколико дође до застоја линије, критично ниског стања одређених залиха, пробијања

рока за извршење одређеног задатка, информатички систем може аутоматски обавестити одговорна лица путем система сигнализације, електронске поште и сл.

Техничка подршка у оквиру Индустрије 4.0 пружа значајне могућности за аутоматизацију и унапређење радних процеса. Уместо да се људи ангажују на рутинским задацима и обради података, технолошки системи преузимају те задатке и обезбеђују брзе и прецизне извештаје, употребом сензора, опреме и алгоритама обраде података. Ова техничка подршка омогућава значајну ефикасност у раду и елиминише потребу за људским ангажовањем у задацима који су рутински или захтевају умерен степен стручности. Пример за то је аутоматско генерисање извештаја на основу прикупљених података, где информатички систем самостално обрађује и представља информације без потребе за интервенцијом човека. Ово значајно убрзава процесе и осигурава конзистентност и тачност података. Уз то, техничка подршка у Индустрији 4.0 омогућава и моментално обавештавање одговорних особа о критичним догађајима или проблемима. На пример, у случају застоја на производној линији или критично ниског нивоа залиха, информатички систем може аутоматски генерисати сигнале или обавести одговорне лице путем електронске поште или других комуникационих канала (Fathi et al., 2019). Ово омогућава брзо и правовремено реаговање на проблеме и минимизира негативне ефекте на производњу и квалитет. Укратко, техничка подршка у Индустрији 4.0 пружа могућности за ефикасно управљање радним процесима и повећање конкурентности. Омогућава аутоматизацију рутинских задатака, генерисање извештаја и брзо обавештавање одговорних особа о критичним догађајима. Ова техничка подршка смањује временске губитке, повећава ефикасност и прецизност рада, и доприноси упрошћавању и унапређењу радних процеса.

Децентрализовано одлучивање је подршка људском кадру од стране сајбер-физичких система (Naugar and Kumar, 2020). Системи могу бити пројектовани да при ниском стању залиха одређеног артикла који је увек потребан и поручиван увек од истог добављача (нпр. репроматеријал) буду аутоматски поручени (Pascual et al., 2020). Систем, на пример може бити пројектован да на трећи узастопни неусаглашен производ (пет у сату или другачије) заустави линију и обавести одговорна лица. -При пријему поруџбенице се може пројектовати систем тако да у складу са порученим производом изврши проверу стања репроматеријала, изда налог за издавање репроматеријала из магацина производној линији, аутоматски обавести руководиоца производње, или чак путем компјутерски управљаних средстава унутрашњег транспорта испоручи материјал на производну станицу и сл. Уколико се систем пројектује тако да доноси одлуке уместо човека, може му се доделити степен ауторизације (Fathi et al., 2019). На пример, ако је систем пројектован да аутоматски поручује репроматеријал може се ставити финансијско ограничење преко ког поруџбину мора одобрити одговорно лице. Ово осигурава контролу и прегледност у процесу и спречава неовлашћено поручивање или непотребне трошкове.

Децентрализовано одлучивање је значајан аспект у Индустрији 4.0 и пружа могућности за ефикасно и брзо одлучивање у радним процесима. Уместо да све одлуке зависе од људског кадра, сајбер-физички системи преузимају одређене одлуке на основу унапред дефинисаних правила и параметара. На пример, системи у Индустрији 4.0 могу бити програмирани да аутоматски поручују репроматеријал када је ниво залиха ниски, без потребе за интервенцијом човека. Ово значајно убрзава процес и осигурава да репроматеријали буду на располагању у правом тренутку. Додатно, системи могу пратити број неусаглашених производа и пријавити их одговорним лицима, што омогућава брзу реакцију и исправку неусаглашености.

Укратко, децентрализовано одлучивање у Индустрији 4.0 пружа могућности за брзо, ефикасно и контролисано одлучивање у радним процесима. Омогућава аутоматско

поручивање репроматеријала, одређивање поступка са неусаглашеним производима и могућност постављања услова и ограничења за одлучивање. Ова технолошка подршка доприноси ефикасности, прецизности и контроли радних процеса, уз осигуравање брзог реаговања на промене и минимизирање грешака (Azizi, 2019).

Технолошки стубови четврте индустријске револуције су (Слика 2.3-1) (Nayyar and Kumar, 2020):

- Интернет ствари (енг. *Internet of Things – IoT*)
- Сајбер-физички системи (енг. *Cyber-physical systems*)
- Рачунарство у облаку (енг. *Cloud Computing*)
- Проширена стварност (енг. *Augmented reality*)
- Анализа великих података (енг. *Big Data Analysis*)
- Сајбер безбедност (енг. *Cyber Security*)
- Напредна роботика (енг. *Advanced Robotics*)
- 3Д штампа (енг. *3D printing*)
- Хоризонтална и вертикална интеграција (енг. *Horizontal and Vertical Integration*)



Слика 2.3-1 Технолошки стубови четврте индустријске револуције (Nayyar and Kumar, 2020)

Интернет ствари је појам који означава умрежавање уређаја путем интернета (Gilchrist, 2016). У домаћинству би то, на пример могло бити умрежавање електронских брава, система видео надзора и детекције покрета, паметних телефона и сл. (Pascual et al., 2020). У оваквој поставци би корисник могао путем интернета приступити систему док је ван дома. Помоћу паметног телефона могао би добити информацију да детектован посетилац (сензори покрета, видео надзор...). Приступом систему за видео надзор би могао установити да је то нпр., достављач и могао би откључати врата куриру и комуницирати са њим путем видеофона. Ово све важи за системе наводњавања, грејне и

расхладне системе, отварање прозора, контролу ролетни на прозорима итд. У оквирима аутомобилске индустрије би на пример, контролор квалитета могао имати динамометарски кључ за статистичку проверу силе затезања вијака који је повезан на интернет. Контролор не би морао да проверава номиналне вредности и толеранције за одређену везу при мерењу, бележи резултате, да их са уређаја пребацује у рачунар итд. Сви подаци би се могли путем интернета складиштити у одговарајући систем који би могао аутоматски генерисати извештај и обавештавати путем е-мејла одговорне особе о резултатима мерења (Zhang et al., 2020).

Интернет ствари представља технолошку концепцију која омогућава умрежавање и комуникацију различитих физичких уређаја и објеката путем интернета (Gilchrist, 2016). Идеја је да сваки уређај буде опремљен сензорима, сигнализацијом и могућношћу комуникације, што им омогућава да обављају различите функције, прикупљају податке и комуницирају са другим уређајима и системима. Интернет ствари има широку примену у различитим областима, укључујући и индустрију. У оквиру индустрије 4.0, интернет ствари је од великог значаја за обезбеђење контроле квалитета и унапређење производних процеса. Напредак у сензорској технологији и могућности умрежавања омогућавају надзор и контролу у реалном времену. У производњи, интернет ствари омогућава сензорима да прикупљају податке о стању машина и опреме, као и параметрима производног процеса. Ови подаци се могу проследити кроз мрежу и обрадити у централном систему за анализу. На основу анализе, могу се детектовати промене и неисправности у реалном времену, што омогућава брзу реакцију и поправку проблема. Ово смањује застоје у производњи и потенцијалне губитке.

Додатно, управљање ланцем снабдевања може бити унапређено применом интернета ствари. Путем сензора и система за праћење, могуће је прецизно пратити кретање робе, контролисати нивое залиха и предвидети потребе за реорганизацијом и набавком. Ово доводи до ефикаснијег управљања инвентаром, смањења трошкова и бољег планирања. Интернет ствари такође отвара могућности за развој паметних производа и услуга. Нпр., „*smart factory*“ и уређаји омогућавају контролу осветљења, температуре, безбедности и енергије на даљину, преко интернета (Zhang et al., 2020). Интелигентни градови имају системе за управљање саобраћајем, осветљењем и управљање отпадом, што доприноси ефикасности и одрживости.

Интернет ствари има потенцијал да промени начин на који функционишу индустрија и пословни свет. Примена ове технологије омогућава боље управљање, већу ефикасност, смањење трошкова и повећање конкурентности. Исправно имплементиран концепт интернета ствари може представљати будућност индустрије и пружа могућности за нове иновације и развој. Интернет ствари имају широк спектар примена у различитим индустријским областима, а њихова вредност лежи у могућности за прецизно прикупљање података, анализу, одлучивање и комуникацију (Gilchrist, 2016). Ова технолошка револуција омогућава савременим компанијама да преузму предност у свету у којем су подаци и брза комуникација од изузетног значаја.

Вештачка интелигенција је програм осмишљен да осликава људско размишљање, људску интелигенцију (Naugar and Kumar, 2020). Као подгрупе вештачке интелигенције могу се издвојити машинско учење и дубоко учење (Azizi, 2019). Сваки вид „размишљања“ машина је нека врста вештачке интелигенције. У свакодневном животу примери вештачке интелигенције су: одређивање најкраће руте до жељене дестинације путем Google мапа, садржај и рекламе на интернет порталима прилагођени понашању корисника на интернету, асистент Siri на паметним телефонима компаније Apple, Google претрага помоћу слике (Pascual et al., 2020). У производној индустрији вештачка интелигенција може бити део многих производних и административних процеса. У оквирима саме производње може се узети хипотетички пример

аутоматизованог пресераја. Уколико је процес производње отпресака потпуно аутоматизован, и може имати време такта од 1 секунд, последица може бити да уско грло таквог процеса постаје одобравање усаглашености делова, односно контрола квалитета производа. Помоћу камера, сензора, ласера и сличних технологија је могуће формирати аутоматски процес верификације исправности делова и производити у складу са максималним капацитетима линије (Vishal et al., 2019). Врло сличан процес је применљив и на производњу каросерије, где се помоћу различитих сонди, сензора и камера могу детектовати неусаглашености заваривања и сл. При монтажи аутомобила је могуће помоћу камера идентификовати зазоре и уравњеност покретних елемената каросерије који су ван толеранције. Користећи вештачку интелигенцију за препознавање облика је могуће утврдити да ли је на ауто уграђена одговарајућа компонента попут фелни, лога, маске браника итд. Вештачка интелигенција у возњи аутомобила користи низ улазних информација и може обезбедити аутономну возњу. Вештачка интелигенција је програм који се мора подучавати и коме се мора обезбедити огромна количина информација (Long et al., 2020). На примеру примене вештачке интелигенције (машинског учења) за одобравање усаглашености заварених спојева је потребно дефинисати параметре који се евалуирају. Следећи корак би био дефинисање прихватљивих и неприхватљивих спојева односно дефинисање граничних вредности за дефинисане параметре (у зависности од приступа). Примера ради, инжењер би примао снимке заварених спојева, евалуирао их и класификовао као усаглашене и неусаглашене, и своју одлуку уносио у електронски систем. Алгоритми вештачке интелигенције би „учили“ из евалуација инжењера и временом бивали оспособљени за аутономну евалуацију (Shukla et al., 2019). Постоји више различитих приступа едукацији система, како је и приказано у наредном поглављу.

Примена вештачке интелигенције у индустрији и контроли квалитета доноси бројне предности и могућности. Од обраде података и детекције неусаглашености до аутоматске евалуације и управљања процесима, вештачка интелигенција игра важну улогу у осигуравању производне ефикасности и квалитета. -Осим тога, вештачка интелигенција има велики потенцијал у аутоматском управљању производним процесима и праћењу квалитета на основу анализе великих података. Системи могу сакупљати и обрадити велику количину података о производњи, испитивањима квалитета и перформансама уређаја. На основу ових информација, вештачка интелигенција може пронаћи корелације, идентификовати проблематична подручја и предложити побољшања у процесима (Borisov et al., 2022).

Сваким даном, вештачка интелигенција открива нове примене у индустрији и контроли квалитета, омогућавајући напредак и иновације у различитим областима. Еволуција ове технологије пружа низ нових могућности које до сада нису биле могуће. Једна од нових примена вештачке интелигенције је употреба алгоритама за предвиђање и спречавање дефекта производа. Системи засновани на методама вештачке интелигенције могу анализирати велике количине података о производним процесима, сировинама и претходним дефектима. На основу ових података, алгоритми могу предвидети потенцијалне проблеме и предложити корективне мере пре него што дође до дефекта (Azizi, 2019). Ово значајно смањује трошкове рекламација и побољшава укупан квалитет производа.

Могућа је и примена вештачке интелигенције код роботизоване визуелне инспекције (машинског вида). Уместо ослањања на визуелну инспекцију производа, работи опремљени камерама и алгоритмима вештачке интелигенције могу прецизно и брзо анализирати квалитет и детектовати могуће дефекте (Mourtzis et al., 2022). Ова технологија осигурава конзистентност и високу тачност при инспекцији, што је

нарочито корисно у индустријским областима где се захтева висок степен прецизности и квалитета.

Вештачке интелигенције је примењива и код уређаја за паметно надгледање и предикцију отказа. Сензори и уређаји умрежени интернетом ствари могу континуирано прикупљати податке о стању машина, уређаја и система. Затим, алгоритми вештачке интелигенције могу анализирати ове податке и предвидети потенцијалне отказе или проблеме пре него што се догоде. Ово омогућава превентивно одржавање и побољшава перформансе, чиме се смањују трошкови неочекиваног заустављања и поправке (Breitenbach et al., 2021).

И након ових примера, важно је истаћи да су могућности вештачке интелигенције безграничне и да се у будућности може очекивати још нових и ефикасних примена ове технологије у индустрији и контроли квалитета. Са сваким новим истраживањем и технолошким напретком, вештачка интелигенција наставља да обликује будућност производње и квалитета, унапређујући ефикасност, сигурност и задовољство корисника. Примена вештачке интелигенције у индустрији и контроли квалитета је значајан напредак који омогућава ефикаснију и прецизнију производњу (Breitenbach et al., 2021). Интеграција интернета ствари и вештачке интелигенције доноси нове могућности и потенцијале у управљању процесима и постизању високог квалитета производа. Овај брзо растући технолошки домен наставља да иновира и мења начин на који индустрија функционише.

Анализа великих података је метод прикупљања велике количине информација и њихова обрада у употребив облик (Ustundag and Sevikan, 2018). Хаотични системи често нису непредвидиви већ су осетљиви на иницијалне услове и постоји превелика количина релевантних информација које људски мозак не може обрадити у циљу предвиђања исхода (Ustundag and Sevikan, 2018). Анализа великих података се може нпр. користити за анализу огромне количине фактора који утичу на временске услове при изради временске прогнозе. Такође се може користити за анализу понашања корисника у интернет окружењу (Pascual et al., 2020). Велики потенцијал може остварити кроз анализу понашања потрошача у циљу предвиђања обима продаје ради ефикаснијег планирања производње (Pascual et al., 2020). При покретању примене методе анализе великих података потребно је одредити параметре који ће се пратити. Код временске прогнозе то могу бити вредности мерене у различитим деловима света попут: температуре; атмосферског притиска; позиције, запремине, густине, смера и брзине кретања облака; влажности ваздуха; позиције и оријентације планете Земље у односу на сунце; концентрације угљен-диоксида и метана у ваздуху; брзине ветра; итд. Када се ови подаци упаре са подацима из претходног периода, надморском висином, рељефом и архитектонском структуром одређене локације могуће је са одређеним степеном прецизности предвидети метеоролошке услове. Идентификујући кључне параметре у неком од индустријских процеса, њиховим мерењем, а затим применом анализе великих података могуће је предвидети: време отказа појединих делова, настанак неусаглашености процеса или производа, број поруцбина и још много тога.

Анализа великих података, позната и као *Big Data* анализа, представља савремени приступ у области обраде и интерпретације великог обима података (Ustundag and Sevikan, 2018). Са развојем информационих технологија и растом доступности података, постало је неопходно развијати методе и алате који омогућавају ефикасну и детаљну анализу ових масивних скупова података.

Примена анализе великих података у индустрији и контроли квалитета пружа бројне предности и могућности. Једна од примена је анализа података о квалитету производа. Узимајући у обзир велику количину параметара и фактора који утичу на квалитет производа, анализа великих података омогућава откривање скривених

корелација и образаца (Gunal, 2019). На пример, коришћењем алгоритама машинског учења и дубоког учења, могу се идентификовати варијабилности у производном процесу које доводе до неусаглашености или дефекта, пружајући могућност за превентивно реаговање и побољшање квалитета производа.

Могућа је и примена анализе великих података у предвиђању потреба и тенденција потрошача. Преко претходних података о куповним навикама, друштвеним мрежама и демографским информацијама, анализом великих података се може предвидети потреба потрошача и персонализовати понуда производа и услуга. Ова предвиђања могу служити као водич за компаније у планирању производње, као и изради стратегија маркетинга, што може довести до бољег ангажовања потрошача, повећања продаје, и избећи прекомерну производњу (Azizi, 2019).

Примена анализе великих података могућа је и у оптимизацији производних процеса. Испитивање података о производним линијама, сензорима и контролним тачкама може открити ефикасне начине за уштеду ресурса, смањење губитака и повећање производне ефикасности. На пример, анализом великих података могу се открити оптимални временски интервали за одржавање опреме, препоручити најефикаснији редоследи операција или пронаћи најбоље поставке машина.

Анализа великих података има потенцијал да промени начин на који индустрија функционише и да пружи нове увиде и могућности за унапређење процеса и квалитета. Интеграција ових метода и алата у индустријске окружење може довести до ефикаснијег и конкурентнијег пословања, откривања нових приступа и подстицања иновација.

Рачунарство у облаку је појам који означава складиштење података у систему који је ван физичке локације корисника, и коме се може приступити путем интернета (Nayyar and Kumar, 2020). Пружаоци услуге рачунарство у облаку нуде неколико видова „издавања“ ресурса кориснику у виду: инфраструктуре, платформе или софтвера (Gunal, 2019). У оквиру инфраструктуре пружалац услуге обезбеђује сервер, складиште података, умрежавање, одржавање, заштитни зид и сл. Корисник обезбеђује апликацију, оперативни систем, податке, посредовање итд. Ову услугу користе на пример систем администратори. Код платформе као услуге корисник обезбеђује само апликацију и податке, а пружалац услуге обезбеђује инфраструктуру, оперативни систем, алате за развој и тест софтвера итд. (Kavis, 2014). Велики број софтвера који се користе свакодневно су складиштени у облаку. Опција софтвера као услуге кориснику омогућава да креирањем личног налога на облаку истог трена користи одређени софтвер (Kavis, 2014). Примери софтвера у облаку су: *Gmail*, *Office 365*, *One Drive*, *Dropbox*, *WeTransfer* и сл. Рачунарство у облаку производној индустрији омогућава брз проток информација као и централно складиште података за више производних локација.

Рачунарство у облаку има широк спектар примена и предности у различитим индустријским областима. У производној индустрији, овај концепт отвара многе могућности за побољшање ефикасности и оптимизацију процеса. Једна од примена рачунарства у облаку у производњи је употреба виртуелних приватних мрежа (VPN) за повезивање различитих локација и централа (Salhaoui et al., 2019). Ово омогућава брз и сигуран приступ и размену података између тимова за одржавање и управљање на различитим локацијама.

Додатно, рачунарство у облаку пружа производним компанијама могућност да користе складиштење и анализу великих података за доношење бољих одлука и унапређење квалитета производа. Огромне количине података које се прикупљају у свакој активности производног процеса могу бити складиштене у облаку и анализиране коришћењем напредних алгоритама и метода машинског учења. Ово омогућава проналажење скривених образаца, идентификацију узрочно-последичних веза и предвиђање проблема и неисправности у реалном времену (Haghnegahdar et al., 2022).

Један од значајних аспеката рачунарства у облаку је и могућност да компаније имају приступ најновијим верзијама софтвера и алатима без потребе за локалном инсталацијом и одржавањем. Ово пружа флексибилност и могућност лаког приступа и коришћења различитих апликација и услуга преко облака, без захтева за инфраструктурне инвестиције уз скраћено време интеграције време.

Рачунарство у облаку такође отвара врата за колаборацију и дељење информација унутар компаније и са спољним сарадницима (Salhaoui et al., 2019). Коришћење алата за колаборацију складиштених у облаку омогућава тимовима да раде несметано и деле резултате свог рада у реалном времену. Ово побољшава комуникацију и синхронизацију тимова, што доводи до бржег и квалитетнијег развоја производа.

Укратко, рачунарство у облаку је снажан алат за производне компаније који омогућава повећање ефикасности, оптимизацију процеса, доношење бољих и правовремених одлука и побољшање сарадње. Примена овог концепта може довести до подизања нивоа конкурентности и постизања бољих резултата у индустрији.

Сајбер безбедност је област информационих технологија која се бави изучавањем ризика и заштите од сајбер напада (Ustundag and Cevikcan, 2018). Сајбер напади су инфилтрације хакера у информатичке системе са циљем крађе информација или софтвера, оштећења хардвера или софтвера, ометања рада софтвера или пружања одређене услуге (Lezzi et al., 2018). Ови напади могу бити циљани или насумични. Заштиту од сајбер напада обезбеђују заштитни зидови, мамци за хакере, антивируси, системи за енкрипцију података, обученост запослених о потенцијалним опасностима попут „пецања“ и других (Ustundag and Cevikcan, 2018). У оквиру аутомобилске индустрије је заштита од сајбер напада изузетно битна, поготово код великих корпорација. Код великих корпорација углавном постоје тимови за истраживање и развој, било нових технологија, методологија, софтвера и сл. Узевши хипотетички случај корпорације која је уложила неколико година рада, значајну суму новца, рад својих стручњака у развој нове технологије како би била конкурентна на тржишту схвата се да постоји потреба за високим нивоом обезбеђења података. Упадом у информатички систем те корпорације нападач би добио комплетну технологију потпуно бесплатно, а губици за корпорацију би били незамисливи. Безбедност података у облаку је често упитна па се велике корпорације често одлучују за складиштење података на сопственој инфраструктури.

Сајбер безбедност има кључну улогу у заштити информација и информатичких система у различитим индустријским областима. Узрок растућих сајбер напада и комплексност нових претњи захтевају постојану иновацију и унапређење сајбер безбедности. Један од најважнијих аспеката сајбер безбедности је заштита против малвера и злонамерних софтвера. Малвери представљају широк спектар штетних програма који имају потенцијал да инфицирају информатички систем и изазову разне проблеме, укључујући крађу података, шпијунажу, ометање рада и уништење информација (Kayan et al., 2022). Експерти сајбер безбедности морају користити најновије методе и алате за откривање и елиминацију малвера, као и за превенцију будућих напада.

Пораст употребе интернета створио је нове изазове у сајбер безбедности, као што су фишинг напади (енг. *phishing*) и социјални инжењеринг. Фишинг напади укључују преварантске технике које имају за циљ да добију личне информације, као што су лозинке и финансијски подаци. Корисници и запослени морају бити обучени о ризицима фишинга и препознавању превара како би се спречиле нежељене последице (Lezzi et al., 2018). Социјални инжењеринг је још један изазов, који се односи на манипулисање емоцијама и психологијом људи како би се добили неовлашћени приступи

информацијама. Обука запослених и имплементација протокола сигурности помажу у смањењу ризика и одбрани од социјалног инжењеринга.

У сектору финансија, сајбер безбедност има још већи значај. Дигитализација банкарског система и престанак физичких трансакција у великој мери зависе од безбедности информација. Заштита финансијских података и трансакција је кључна за подршку поузданости и поверењу корисника.

Компаније свакодневно улажу у алате и системе за сајбер безбедност, али претње и даље еволуирају. Зато, редовно освежавање и унапређење инфраструктуре и политика безбедности постаје неопходност. Константна вишеслојна заштита, укључујући уграђену заштиту у хардверу и софтверу, праћена ажурирањем и тестирањем, неопходна је за суочавање са новим претњама (Кауан et al., 2022). Сајбер безбедност има виталну улогу у заштити информација и информатичких система. Континуирано надограђивање и прилагођавање сајбер безбедности на нове претње и напредне технологије имају кључну важност за заштиту приватности, безбедности и интереса компанија и корисника.

Проширена реалност је програм који помоћу електронских уређаја ствара привид постојања виртуелних елемената (Mealy, 2018). Уређаји који се користе за то могу бити паметни телефони, рачунари или сетови са посебним наочарима (Ustundag and Sevikcan, 2018). Неопходно је диференцирати појмове виртуелна стварност и проширена стварност. У виртуелној стварности је корисник потпуно урођен у виртуелно окружење, док се код проширене стварности виртуелни елементи пројектују на реално окружење (Mealy, 2018). Примери проширене стварности су нпр. видео игра за мобилне телефоне *Pokémon GO*, додаци камери који мењају изглед корисника или окружења који се могу видети у апликацијама разних друштвених мрежа, апликација компаније VW која показује кориснику како да на аутомобилу изврши сервис или замену одређених делова (Parida et al., 2021). У оквиру производне индустрије се може користити бежични сет наочара за проширену реалност у разним оквирима. Радник на линији може добити усмерења на којој Канбан полици се налази репроматеријал који му је потребан, чиме се убрзава процес рада и смањује могућност узимања погрешне/сличне компоненте. Може се применити као приказ стандардне оперативне процедуре за неку мануелну производну операцију или пак као упутство при пружању прве помоћи другом запосленом.

Сваким даном се откривају нове могућности за примену аугментоване реалности у различитим индустријским областима. У производној индустрији, АР се може користити за оптимизацију процеса производње и помоћ при обуци за рад на машинама и уређајима са повећаним безбедносним ризиком или комплексним радним задацима. Радници могу користити АР наочаре да прате упутства за склапање комплексних уређаја, што смањује грешке и убрзава процес производње (Chen et al., 2019).

Аугментована реалност има широк спектар примена у различитим индустријским областима и сваким даном се откривају нове могућности. Ова иновативна технологија доноси значајан напредак у пословном свету, образовању, медицини, производњи и другим областима. С обзиром на непрестано развијање технологије и креативност људи, могућности аугментоване реалности су безграничне.

У образовном сектору, АР има велики потенцијал за учење и обуку. Могу се креирати интерактивни модели и симулације које омогућавају ученицима да истражују комплексне концепте на визуелно занимљив начин. На пример, ученици могу истраживати соларни систем или анатомију људског тела кроз АР апликације, што им пружа боље разумевање и памћење материјала. Исти принцип се може употребити да прикаже мускуларну структуру запослених који имају лоше држање за рачунаром и потенцијалне ризике дугорочном излагању истом.

Виртуелна реалност представља компјутерски генерисано окружење које пружа кориснику илузију присуства у том окружењу. У индустријском окружењу, виртуелна реалност има значајну улогу у различитим аспектима, од дизајна и развоја производа до обуке и сигурности.

Једна од примена виртуелне реалности у индустријском окружењу је у дизајну и развоју производа. Коришћењем виртуелне реалности, инжењери могу креирати и визуализовати комплексне производне моделе и компоненте у тродимензионалном окружењу (Berg and Vance, 2017). Ово омогућава боље разумевање пројекта и откривање потенцијалних грешака или унапређења пре него што се пређе на физичку израду прототипа.

У области обуке и симулација, виртуелна реалност пружа могућности за реалистично и безбедно обучавање радника. Користећи VR окружење, радници се могу вежбати за извршавање сложених задатака, сигурносних протокола и процедура без ризика по здравље или безбедност (Naranjo et al., 2020). Ова врста обуке помаже у повећању ефикасности, смањењу грешака и оптимизацији радних процеса.

Виртуелна реалност такође има значајну примену у сигурности и безбедности у индустријском окружењу. Коришћењем VR технологије, могу се симулирати опасни услови, катастрофе или несреће и обучавати радници за управљање њима (Naranjo et al., 2020). Овај приступ омогућава претварање потенцијалних ризика у контролисане ситуације и припрему радничког особља за ефикасно реаговање и минимизирање потенцијалних штета и повреда.

Виртуелна реалност такође отвара могућности за сарадњу и комуникацију на дистанци. Радници различитих локација могу се повезивати у виртуелном окружењу и радити заједно на пројектима, симулацијама или обуци. Ово штеди време и трошкове путовања, али и пружа могућност за ефикасну размену идеја и колаборацију између различитих тимова и стручњака. Виртуелна реалност има значајан утицај на индустријско окружење, пружајући нове начине дизајнирања, обучавања и управљања безбедношћу.

Напредна роботика је већ дужи низ година присутна у производној индустрији. Напредни роботи су у аутомобилској индустрији ефикасно присутни у производњи каросерије и обављају операције заваривања и манипулације деловима. У другим индустријским областима напредна роботика може бити примењена у процесима склапања, паковања, манипулације, контроле итд. (Machado et al., 2022). Са развојем роботике и вештачке интелигенције појавили су се и “хуманоидни” роботи који се могу користити уместо курира или за обављање одређених операција у условима у којима би то за човека било немогуће (Vrontis et al., 2022).

Напредна роботика у индустрији има потенцијал да трансформише начин на који се производе и обрађују различити производи. Роботи са напредним способностима могу учинити производне процесе ефикаснијим, прецизнијим и сигурнијим.

У примарној производњи, напредни роботи могу извршавати захтевне операције у тешким окружењима. На пример, у рударској индустрији, роботи могу бити коришћени за рударење и транспорт тешких материјала. Ово не само да смањује опасност и здравствене ризике за раднике, већ и побољшава ефикасност и прецизност у процесу производње.

У области авијације, роботика игра значајну улогу у изради комплексних компоненти и монтажи. Напредни роботи су способни да извршавају сложене операције на ваздухопловним деловима, као што су заваривање, завијање, као и провера квалитета. Ово помаже у повећању прецизности и сигурности у процесу производње ваздухопловних компоненти. У области медицине, напредна роботика има велики потенцијал за прецизну и комплексну хирургију. Хируршки роботи могу бити

коришћени за извођење сложених операција, као што су минимално инвазивне хируршке процедуре и тачкаста манипулација ткива. Ово може смањити ризик од грешака и донети боље резултате за пацијента (Sherwani et al., 2020).

У складу са развојем и применом напредне роботике, потребно је превазићи одређене изазове и препреке, као што су безбедност, етика и обука. Важно је осигурати да работи буду безбедни за рад у близини људи и да поштују прописане стандарде безбедности. Обука и едукација радника за рад са роботима су такође од великог значаја.

Напредна роботика има неограничен потенцијал за примену у различитим индустријским областима и наставља да се развија и напредује. Ова иновативна технологија има могућност да подигне ефикасност, прецизност и безбедност у производњи, што доприноси напретку и развоју индустрије у целини. Са додатним истраживањима и унапређењима, напредна роботика ће наставити да мења начин на који ће се производња одвијати у будућности (Sherwani et al., 2020).

3Д штампа је производња адитивном методом, насупротив формативне, и производње одузимањем материјала (Jandyal et al., 2022). Адитивна производња има своје недостатке, али такође има пуно предности. Предности адитивне производње су: могућност израде комплексних делова употребом 3Д модела у електронском облику, производња безброј комада на основу једног 3Д модела, регулација густине/маса штампаног дела, прецизност израде, израда облика за које је производња другим методама готово немогућа, израда модела комбиновањем више различитих материјала, израда састављених склопова, редукција отпадног материјала (Shahrubudin et al., 2019).

3Д штампа је револуционарна технологија која има све већу примену у индустрији. Ова техника омогућава производњу тродимензионалних објеката слојевима материјала који се наносе један на други, чиме се остварује прецизност и комплексност у изради.

Једна од главних предности 3Д штампе у индустрији је могућност израде сложених делова који би били тешко или немогуће произвести другим методама. Захваљујући 3Д моделима у електронском формату, дизајнери могу креирати геометријски комплексне облике са великом прецизношћу (Jandyal et al., 2022). Ова технологија отвара врата новим дизајнерским могућностима и креативном изражавању.

Још једна предност 3Д штампе је могућност масовне производње истих или различитих предмета на основу једног 3Д модела. Ово омогућава ефикасност и смањење трошкова производње, посебно када је реч о мало-серијској или прилагођеној производњи (Jandyal et al., 2022).

Јединствена могућност 3Д штампе је регулација густине или масе штампаног дела. Овај параметар се може подешавати током процеса штампе, чиме се добијају предмети различитих карактеристика и перформанси. На пример, захтеван предмет може бити израђен са мањом густином како би био лакши или са већом густином како би био чвршћи и издржљивији. Још једна важна могућност 3Д штампе је комбиновање више различитих материјала приликом израде једног модела (Shahrubudin et al., 2019). Ово отвара простор за стварање сложених склопова, унутрашњих структура и функционалних делова који су раније били тешко изводљиви.

Уз све наведене предности, 3Д штампа такође доприноси смањењу отпадног материјала у процесу производње (Shahrubudin et al., 2019). Ова технологија користи материјале само тамо где је то потребно, чиме се смањује губитак ресурса и негативан утицај на животну средину. Напредак у области 3Д штампе отвара врата за иновације у индустрији. Очекује се да ће се ова технологија даље развијати, пружајући још више могућности за дизајнере и произвођаче широм света. 3Д штампа ће наставити да трансформише индустријске процесе, поспешујући ефикасност, креативност и напредак у производњи различитих предмета (Gunal, 2019).

Сајбер-физички системи су комбинација неколико горе-поменутих технологија које конституишу производне или услужне системе (Gilchrist, 2016). Системи у којима су уређаји повезани путем интернета, поседују вештачку интелигенцију, радници користе опрему за аугментовану стварност, производња се обавља помоћу напредних робота, (као и примена других технологија) називају се сајбер-физички системи (Gilchrist, 2016).

Сајбер-физички системи играју значајну улогу у индустријском окружењу, пружајући напредне могућности и омогућавајући повећану ефикасност и конкурентност. Једна од примена сајбер-физичких система је у управљању производним процесима. Путем сензора и мрежне повезаности, системи могу континуирано пратити стање машина и опреме, обавештавати о одступањима и предвидети могуће кварове (Gilchrist, 2016). Ово омогућава превентивно одржавање и смањује прекиде у производњи.

Сајбер-физички системи такође омогућавају прецизну и синхронизовану комуникацију између различитих делова система. Роботи, машине и радници могу бити повезани путем мреже, што олакшава дељење информација, координацију активности и брзо реаговање на промене (Gilchrist, 2016). На пример, у складиштима или производним линијама, роботи могу комуницирати са системом управљања и дељења података, и обављати задатке са великом прецизношћу и ефикасношћу.

Укључивање сајбер-физичких система у индустријску средину захтева сарадњу између различитих сектора и експертизу из области информационих технологија, роботике и управљања производњом (Shukla et al., 2019). Ова интеграција отвара нове могућности за индустријске компаније, усмеравајући их ка интелигентним и флексибилним системима који могу ефикасно одговорити на потребе тржишта и створити конкурентску предност. У будућности, сајбер-физички системи ће наставити да развијају своје могућности и примене, пружајући нам нове начине за оптимизацију и надградњу индустријских процеса (Gunal, 2019).

Хоризонтална и вертикална интеграција су појмови који описују приступе стварању инфраструктуре за Индустрију 4.0 (Pascual et al., 2020). Вертикална интеграција претходно описаних технологија се односи на процесе унутар компаније (Pascual et al., 2020). Између осталог, то би били процеси: производње, набавке, логистике, управљања квалитетом, развоја процеса и производа, управљања пројектом итд. Хоризонтална интеграција претходно описаних технологија се односи на усклађивање приступа пословању добављача производа и услуга, корисника, и купаца са начином пословања дате компаније (Azizi, 2019). Потребно је обезбедити адекватан проток информација, у одговарајућем облику да би систем могао функционисати. Након тога је потребно обезбедити адекватну анализу информација и њихову формулацију у употребив облик.

Хоризонтална и вертикална интеграција у контексту индустрије 4.0 имају значајну улогу у подизању ефикасности и конкурентности у индустријском окружењу (Pascual et al., 2020). Вертикална интеграција обезбеђује синхронизацију различитих процеса унутар компаније, од поља набавке до производње и логистике. Вертикална интеграција омогућава бољу координацију и управљање процесима, минимизирајући грешке и оптимизујући производне циклусе (Pascual et al., 2020).

С друге стране, хоризонтална интеграција се фокусира на побољшање сарадње и комуникације између различитих актера у индустријском окружењу. Она омогућава проток информација и података између различитих пословних партија, укључујући добављаче, кориснике и купце. Кроз поделу релевантних информација и боље разумевање потреба и захтева свих учесника, хоризонтална интеграција подстиче боље пословне односе, бржи одзив и већу прилагодљивост (Pascual et al., 2020).

У индустријском окружењу, хоризонтална и вертикална интеграција се додатно подржавају напредним технологијама. На пример, употреба Интернета ствари и сензорске мреже омогућава аутоматизацију и покретање роботизованих система на различитим нивоима производње. Ово доприноси ефикаснијој комуникацији између машина и података, што резултује побољшаном контролом и управљањем процесима. Хоризонтална и вертикална интеграција у индустријском окружењу, подржана напредним технологијама, пружају многобројне предности у области ефикасности, квалитета, комуникације и управљања производњом. Ова интеграција је кључна за развој индустрије 4.0 и подстиче конкурентност и иновације у индустријском окружењу (Ustundag and Cevikcan, 2018).

Потребно је појаснити да технологије које су поменуте у овом раду нису тако нове као што не информисанима може деловати. Све поменуте технологије су настале пре неколико деценија али је било потребно време за њихов развој и технолошку инфраструктуру која би их могла подржати. Ево само неколико примера технологија:

- **Интернет (~50 година присутан)** – ARPAnet је настао 1969. године као претеча интернета који је данас познат (Hauben, 1998)
- **Персонални рачунар (~40 година присутан)** 1981. године су на тржиште ступили рачунари компаније ИВМ који су били претеча персоналних рачунара који су данас заступљени, иако рачунари постоје још од краја 30-их година прошлог века (Computer History Museum, 2021)
- **Светска мрежа (~30 година присутна)** „World wide web“ је настала почетком 90-их година прошлог века као иницијатива Тима Бернерс-Лија (Shadbolt and Berners-Lee, 2008)
- **Индустријски роботи (~60 година присутни)** први индустријски робот *UNIMAT* настао је 1961. године (Leider, 2015)
- **Бежична комуникација (~25 година присутна)** „WiFi“ је са развојем транзистора крајем 90-их година прошлог века почела да наликује бежичној мрежи која се данас користи (Golio, 2008)
- **Вештачка интелигенција (~70 година присутна)** прву вештачку неуронску мрежу је 1943. године развио неуропсихијатар Ворен МекКулок (Anderson and McNeill, 1992)
- **3Д штампа (~35 година присутна)** средином 80-их година прошлог века је Чарлс Хол применио стерео литографију у сврху адитивне производње (Redwood et al., 2017)
- **Интернет ствари (~40 година присутан)** први пример умрежавања уређаја путем интернета је био почетком 80-их година прошлог века повезивањем машине за продају Кока Коле са рачунаром на универзитету Карнеги Мелон путем интернета (Carnegie Mellon University, 2018)
- **Проширена реалност (~50 година присутна)** 1967. године је Иван Шатерленд, професор на универзитету Харвард, конструисао прву кацигу за аугментовану стварност (тада су виртуелна и проширена реалност имале скоро исто значење) (Nee and Ong, 2023)

Узевши у обзир да технологије које данас постају популарне нису тако нове као њихова популарност, едукацијом кадра унутар организације може се смањити одбојност ка промени начина рада.

2.4 Напредне технологије недеструктивног типа у области контроле квалитета

Аутомобилска индустрија представља једну од најзахтевнијих индустрија у погледу квалитета, безбедности и поузданости производа (Bergmann et al., 2007). У овом истраживању, фокус је стављен на примену *Lean* методологије у аутомобилској индустрији, а преко ИБР, анализира се потенцијална ефикасност и ефективност оваквог приступа.

Производња аутомобила је комплексна и захтевна, са мноштвом могућности за грешке, чак и када су компоненте исправне и добро усаглашене. С обзиром на то да многи различити добављачи производе делове за истог произвођача аутомобила, постоји експоненцијално повећан ризик од производње дефектних возила уколико су компоненте неисправне. Ово наглашава значај квалитета и надзора над производњом у целокупном ланцу снабдевања.

Како би се осигурао квалитет и сигурност у производњи, неопходно је да добављачи у аутомобилској индустрији имају за циљ производњу без дефеката. У случају непоузданих или ризичних процеса производње, неопходно је извршити 100% проверу делова. Када је производни процес стабилан и поновљив, али је повезан са специфичном карактеристиком производа, могуће је применити статистичку контролу процеса.

Тестови представљају важан аспект у производњи, али неки од њих могу бити деструктивни и генерисати додатне трошкове. Деструктивни тестови се користе у случајевима када је потребно испитати квалитет, перформансе или безбедност производа, али се при томе губи сам производ или полупроизвод. Овакви тестови су, на пример, неопходни за боље разумевање квалитета процеса и оптимизацију параметара производње, али и имају висок потенцијални ризик.

У прошлости, примена ИБР у аутомобилској индустрији била је ограничена (Blouin et al., 2008). Технолошке баријере и недостатак ефикасности били су препрека за широку примену ових метода. Међутим, данас постоје различите напредне методе ИБР које омогућавају поуздану и ефикасну анализу у аутомобилској индустрији (Ding et al., 2022; Machado et al., 2022, 2021). Ове методе постављају нове стандарде и трендове, доприносећи унапређењу квалитета, безбедности и поузданости производа.

ИБР играју кључну улогу у постизању изврности у аутомобилској индустрији. Правилно примењена, ова тестирања могу значајно смањити ризик од дефеката и неисправности, доприносећи високом квалитету производа и задовољству купаца. Њихова примена треба да буде интегрални део производних процеса и део стратегије компанија у аутомобилској индустрији, што ће осигурати да се достигну највиши стандарди квалитета и безбедности.

Захтеви за тестирањем постају све строжији у аутомобилској индустрији, а како би остале конкурентне (у смислу квалитета и трошкова) добављачке компаније морају да прате актуелне трендове у напредном тестирању (Misokefalou et al., 2022). Неки тестови су веома захтевни и могу захтевати високу мерну резолуцију (Bergmann et al., 2007). Зависно од комплексности и својстава тестираног дела, неке методе ИБР можда неће бити применљиве. Ипак, деструктивно тестирање је било стандард у аутомобилској индустрији дуги низ година. Деструктивно тестирање је најчешће статистичког типа и може бити комплексно, веома скупо, временски захтевно, штетно по здравље оператера, опасно. Оно може такође захтевати вишеструке методе испитивања/кораке како би се добио жељени резултат, производи отпад, и може имати низак потенцијал за

дигитализацију процеса (Bergmann et al., 2007)(Misokefalou et al., 2022)(Changliang et al., 2017).

У циљу развоја 100% линијског решења за тестирање, које ће бити безбедно, ефикасно, поуздано и брзо, а уједно и штедети на инвестицијама и имати кратки рок поврата инвестиција (ROI), анализирале су се различите ИБР методе. Свака од тих метода има своје предности и ограничења, и приликом избора треба разматрати неколико фактора, укључујући специфичне потребе и услове компаније, доступну опрему и техничку експертизу.


Најчешће коришћене недеструктивне методе су (Maduru et al., 2017): ултразвучно испитивање, испитивање помоћу магнетних честица, пенетрантно испитивање, термографија, испитивање помоћу вртложних струја, рендген/компјутерска томографија и вештачка интелигенција – машинско учење. Неке од ових метода су погодније за примену у оквиру овог експеримента од других. Свака од ових метода има своје предности и недостатке.

Свака од ових метода има своје специфичне примене и предности. На пример, визуелно испитивање је једноставно и приступачно, док ултразвучно испитивање омогућава детекцију малих дефеката унутар материјала. Магнетно испитивање се користи за испитивање и откривање површинских грешака код магнетних материјала, док се радиографија примењује за испитивање структура високе густине и комплексних структура (Bergmann et al., 2007).

Напредак у технологији ИБР омогућио је развој нових и иновативних метода испитивања. На пример, компјутерска томографија (СТ) и дигитална радиографија пружају детаљне тродимензионалне слике, што олакшава откривање скривених дефекта. Такође, термографија може открити аномалије у топлотним обрасцима, што је корисно за испитивање топлотних система и компоненти. Укратко, напредак у методама ИБР пружа нове могућности за ефикасно испитивање и контролу квалитета у аутомобилској индустрији. Примена одговарајућих метода ИБР може допринети повећању квалитета производа, смањењу ризика и трошкова, и већем задовољству купаца (Misokefalou et al., 2022).

Ултразвучно испитивање представља могућу методу за статистичку контролу процеса у аутомобилској индустрији. Она се заснива на примени ултразвучних таласа који се пропуштају кроз тестиране делове или материјале, а затим се региструју и анализирају добијени ехои-сигнали (Слика 2.4-1). Ултразвучна тестирања могу бити изузетно корисна у детекцији дефеката и оцени интегритета материјала без неопходности деструктивног испитивања (Honarvar and Varvani-Farahani, 2020).

За успешно извршавање ултразвучне провере, обично је потребно применити течност или гел између ултразвучне сонде и тестираног дела (Ding et al., 2022). Овај медијум помаже ултразвучним таласима да се пренесу без губитка или рефлексације и обезбеђује бољи контакт између сонде и површине дела. Извршена провера омогућава детектовање потенцијалних дефеката, као и одређивање локације и карактеристика дефекта, као што су величина, дубина или природа дефекта (Honarvar and Varvani-Farahani, 2020).



Слика 2.4-1 Шематски приказ ултразвучног испитивања (Jamil et al., 2019)

Међутим, треба имати на уму да ултразвучна провера може имати своја ограничења у неким ситуацијама. На пример, приликом тестирања залемљених спојева, где је дебљина споја око 700 μm , ултразвучна метода може постати непоуздана за објекте мање величине (мање од половине таласне дужине примењених таласа) (Ding et al., 2022). Такође, примена ласерске ултразвучне методе може помоћи у побољшању резултата, али би и даље представљала изазов за поуздану интерпретацију добијених сигнала код малих залемљених спојева (Ding et al., 2022). Ту се јавља потреба за детаљним проучавањем и развојем напредних метода које би обезбедиле поузданије и ефикасније ултразвучне провере.


Уз развој технологије, истраживачи су пронашли начине за унапређење ултразвучне провере. Један од примера је развој бесконтактне ултразвучне методе користећи ваздух као медијум за проверу споја на челичним лимовима дебљине 3 mm (Vasilev et al., 2021). Ова иновативна метода има потенцијал да премости неке претходне ограничености и отвори нове могућности у аутомобилској индустрији.

Укључивање вештачке интелигенције у процес ултразвучне провере такође може бити значајно. Алгоритми машинског учења и дубоког учења могу се користити за интерпретацију ултразвучних резултата и аутоматску детекцију дефеката (Provencal and Lapergière, 2021). Ово може значајно унапредити брзину и тачност процеса провере, али и донети нове могућности у аутоматизацији и оптимизацији квалитета у производњи аутомобила.

Укратко, ултразвучна провера представља важан алат у аутомобилској индустрији за контролу квалитета и детекцију дефеката. Уз развој нових технологија, метода и употребу вештачке интелигенције, она може постати још поузданија и ефикаснија. Ипак, ултразвучна провера има своја ограничења, поготово када су у питању мали делови и специфични услови тестирања на производној линији. Стални напредак и истраживање у овој области ће допринети да се постигне још већа ефикасност и ефективност ултразвучне провере у аутомобилској индустрији.

Испитивање помоћу магнетних честица представља методу ИБР која се користи у различитим индустријским областима, укључујући аутомобилску. Ова метода се фокусира на откривање дефеката и недостатака у феромагнетним материјалима, као што су већина челика и челичних спојева. Применом магнетних честица, које су обично прах или суспензија магнетних материјала, на површину објекта и применом магнетног

поља, дефекти или недостаци се откривају кроз нагомилавање или раскидање честица (Слика 2.4-2) (Singh, 2020). Ово омогућава операторима да визуелно примете и оцене присуство и природу дефекта.




Слика 2.4-2 Шематски приказ тестирања помоћу магнетних честица (Zolfaghari et al., 2018)

Ипак, при примени испитивања помоћу магнетних честица на производној линији, постоје нека важна питања која треба разматрати. Један од њих је техничка чистоћа. Производни процеси у аутомобилској индустрији захтевају висок ниво техничке чистоће (Zolfaghari et al., 2018). Примена магнетних честица може бити проблематична у производним условима, јер би прах могао да допре до шупљина и остане ту, што може утицати на функционалност и квалитет производа (Singh, 2020). Додатно, важно је разматрати и потенцијалне опасности за оператере. Када се примењује метода испитивања помоћу магнетних честица, постоји могућност за контакт са штетним или отровним материјама. Зато је неопходно предузети одговарајуће безбедносне мере, као што су употреба заштитне опреме и обука оператора.

Укратко, испитивање помоћу магнетних честица је важна метода за откривање дефеката и недостатака у феромагнетним материјалима у аутомобилској индустрији. Међутим, у условима производне линије са високим захтевима техничке чистоће, примена ове методе може бити изазовна. Потребно је разматрати техничку чистоћу, опасности за оператере и примену прописних безбедносних мера. Истраживање и развој алтернативних метода испитивања које би биле прилагођене специфичним условима и захтевима производне линије може донети напредак у области контроле квалитета помоћу магнетних честица у аутомобилској индустрији.

Пенетрантно испитивање или испитивање течним пенетрантима је још једна метода ИБР која се користи за откривање површинских дефеката на материјалима. Ова метода укључује примену специјалних хемикалија, познатих као пенетрантне течности, које имају способност да продру у микро-пукотине, порозност или друге површинске дефекте објекта. Након наношења пенетранта и уклањања вишка, примењује се развијач

који подстиче излазак пенетранта на површину дефекта, стварајући визуелни сигнал присуства одређене индикације (грешке) (Слика 2.4-3). Ова метода се најчешће користи за откривање дефеката на металним површинама, укључујући залемљене и заварене спојеве.

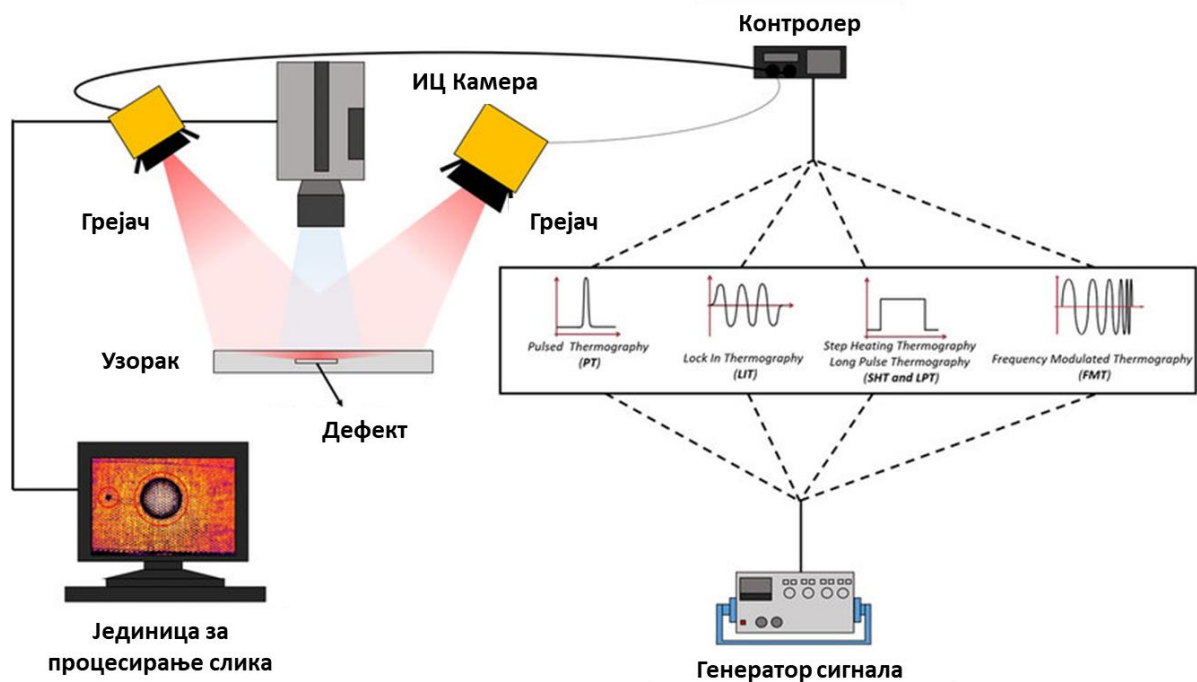


Слика 2.4-3 Шематски приказ пенетрантног тестирања (Manikandan et al., 2021)

Међутим, у случају одређених потреба испитивања у производним условима, пенетрантно испитивање није прикладно из истог разлога као и испитивање помоћу магнетних честица. Ово тестирање захтева прецизно чишћење и сушење дела, наношење пенетранта, уклањање вишка, примену развијача и одређено време за реакцију (Manikandan et al., 2021). Овај процес је временски захтеван и може контаминирати делове. Осим тога, шупљине и пукотине унутар нпр. залемљеног или завареног споја не могу бити ефикасно детектоване коришћењем пенетрантног тестирања (Guirong et al., 2015). У овој примени, могуће је истражити алтернативне методе испитивања које су прилагођене специфичним условима и захтевима пројекта. Примена напредних технологија, као што су компјутерска томографија или термографија, могла би понудити боље резултате у детекцији дефекта у залемљеним спојевима, без потребе за дуготрајним процесима припреме и провере. Такође, развој нових материјала са унапређеним карактеристикама може допринети повећању квалитета и безбедности спојева у аутомобилској индустрији.

Укратко, пенетрантно тестирање, иако је корисна метода за откривање површинских дефеката, није прикладно за сваки пројекат у аутомобилској индустрији, поготово за примену у производним условима. Неопходно је истражити и разматрати алтернативне методе испитивања које би биле прилагођене специфичним условима и захтевима радног окружења, како би се обезбедила ефикасна и поуздана контрола квалитета залемљених спојева.

Термографија представља напредну методу неструктивног испитивања која користи инфрацрвену технологију за откривање и визуелизацију недостатака и аномалија на површинама објеката. У овој методи, на тестираном објекту се примењује одређена топлотна стимулација, на пример, помоћу светлосне лампе, која генерише топлоту. Затим, инфрацрвена камера снима инфрацрвену емисију која потиче од објекта и претвара је у топлотну слику (Слика 2.4-4). Ова слика омогућава визуелни приказ различитих топлотних потписа, што омогућава откривање недостатака и аномалија на испитиваном делу (Kumar and Reddy, 2018).



Слика 2.4-4 Шематски приказ термографског тестирања (Сиапра et al., 2018)


У случају залемљених и заварених спојева, термографија може бити примењена као пасивна метода, где се топлота генерише самим процесом спајања, као што је лемљење или заваривање. Инфрацрвена камера примећује разлике у топлотним потписима који се јављају у близини недостатака или несавршености залемљеног или завареног споја. Ова метода је брза, ефикасна и поуздана, посебно у окружењима са високим температурама и на компонентама већих димензија (Kumar and Reddy, 2018) (Siegel et al., 2020).

Ипак, примена термографије није увек најбољи избор, разлози за то су повезани са захтевима и ограничењима производне линије. Опрема за брзо термографско испитивање у линијским условима може бити скупа и може захтевати значајне измене на производној станици. Такође, скенирање на другој локацији у фабрици би захтевало модификације на производној линији и одобрење од стране купца. Преговори са купцем око оваквих измена могу бити дуготрајни, а купчеви захтеви додатно поскупети пројекат имплементације нове методе тестирања (Kumar and Reddy, 2018) (Siegel et al., 2020).

Суштински, термографија представља напредну методу за откривање недостатака у залемљеним спојевима, али у овом пројекту је изабрано друго решење због захтева и ограничења производне линије. Ипак, истраживање и развој нових технологија и приступа у термографији може донети напредак у области испитивања залемљених спојева и квалитетне контроле у аутомобилској индустрији .

Испитивање помоћу вртложних струја представља изузетно корисну методу за откривање и анализу дефекта на површинама и унутар различитих материјала. Ова техника се често користи у аутомобилској индустрији за испитивање залемљених спојева и других важних компоненти.

Испитивање помоћу вртложних струја је техника ИБР која се користи за процену и детекцију дефекта у металима и проводницима. Ова техника заснива се на принципу електромагнетне индукције, где се промена магнетног поља индукује излагањем метала вртложним струјама (Слика 2.4-5). Примена ове технике у инспекцији материјала омогућава брзо откривање скривених дефекта, контролу квалитета и процену структурних својстава без оштећења испитиваног објекта.



Слика 2.4-5 Шематски приказ тестирања помоћу вртложних струја (Hwang et al., 2015)

Поред способности да открива дефекте малих димензија, испитивање помоћу вртложних струја такође пружа неке друге предности. На пример, ова метода не захтева контакт између испитивача и објекта, што је од велике важности у случају осетљивих компоненти и материјала (AbdAlla et al., 2019). Такође, она може бити примењена на широк спектар површина, укључујући и комплексне геометрије (Machado et al., 2021). Још једна предност испитивања помоћу вртложних струја је могућност аутоматизације и интеграције у производни процес. Напредак у области роботске технологије и аутоматских контролних система омогућава примену ове методе у склопу роботизованих система или интеграцију у производне линије. Ово доводи до побољшане ефикасности, конзистентности и пуноће контроле квалитета.

Иако испитивање помоћу вртложних струја представља моћну методу, она није адекватан избор за сваки пројекат због одређених ограничења. Могући разлози укључују комплексност интеграције, потребу за додатном опремом и инфраструктуром, као и потребу за обученим и стручним особљем. Ипак, треба имати у виду да ова метода има широку примену у другим областима, нарочито за испитивање тањих материјала попут фолија, и да је њена примена у аутомобилској индустрији и даље предмет истраживања и развоја.


Укратко, испитивање помоћу вртложних струја представља ефикасну и доказану методу за откривање дефекта у залемљеним спојевима. Има предности у виду откривања малих дефеката, могућности без контактнoг испитивања и могућности аутоматизације (Machado et al., 2021). Ипак, у овом пројекту је изабрана друга опција због специфичних услова и захтева. Независно од тога, испитивање помоћу вртложних струја има потенцијал за будући развој и примену у контроли квалитета у аутомобилској индустрији.

Рендген и компјутерска томографија представљају моћне алате за испитивање залемљених спојева и откривање дефекта. Ове методе имају способност да пруже детаљан увид у својства и структуру споја, открију недостатке веома мале величине или измере димензије делова или дефекта. Компјутерска томографија, посебно, пружа

могућност за добијање тродимензионалних мерења делова и дефекта, што значајно обогаћује резултате анализе и испитивања (Galos et al., 2021; Namade and Baydoun, 2019).

Испитивање материјала помоћу рендгенских зрака је техника ИБР која се користи за детекцију и анализу скривених дефекта у различитим материјалима. Ова техника заснива се на примени рендгенских зрака који пролазе кроз испитивани објекат и стварају сенке (затамњења одређеног степена) или апсорпционе слике на детекторима (филмовима) (Слика 2.4-6). Применом одговарајућих алгоритама и анализом добијених слика, могуће је добити информације о структури материјала, дефектима, присутним органским или неорганским супстанцама и другим карактеристикама испитиваног материјала (Galos et al., 2021; Namade and Baydoun, 2019). Испитивање материјала помоћу рендгенских зрака има широку примену у индустрији, медицини, археологији и другим областима где је битно непрекидно надгледати и анализирати квалитет и структурне својства различитих материјала.

Међутим, употреба ових метода захтева одговарајуће обучено особље и специфичну опрему. Ове технике изискују наменски испитни простор, специфичан рачунар и доста времена за обраду и анализу резултата. Цена опреме је такође релативно висока, посебно у контексту линијског тестирања са ограниченим простором и брзим процесима. Треба имати у виду да се цена опреме значајно повећава са захтевима за високом резолуцијом скенирања (Wankerl et al., 2020; Xiao et al., 2021).



Слика 2.4-6 Шематски приказ радиографског тестирања (Arifin et al., 2018)

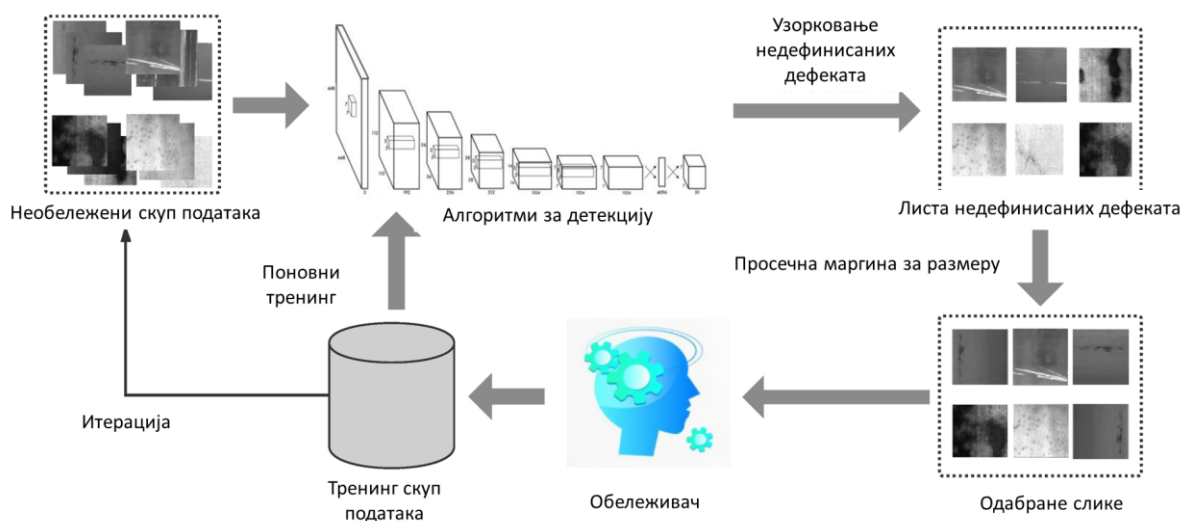
Идеја да се рендгенско и компјутерско томографско скенирање употреби као замена за више деструктивних тестова у фабрици представља потенцијално значајан напредак. Овај приступ би могао да донесе уштеду у периоду поврата инвестиције због смањених трошкова улагања и веће ефикасности употребе опреме. Употреба рендгена се може конципирати као централизована контролна станица за више различитих производа и врста тестова, што би омогућило инвестиционе уштеде наспрам засебног

решења за сваки производ или тест. Анализа и интерпретација добијених резултата скенирања могла би значајно да се побољша и употребом вештачке интелигенције, што би допринело у побољшању ефикасности и аутоматизације процеса (Wankerl et al., 2020; Xiao et al., 2021).

У закључку, рендгенско и компјутерско томографско скенирање представљају напредне методе испитивања које пружају детаљан увид и мерење својстава производа. Ипак, изазове представљају висока цена опреме, потреба за обученим особљем, трајање тестова, као и трајање интеграције решења у производном постројењу. Ове методе представљају потенцијално значајано поље истраживања и развоја у домену контроле квалитета у аутомобилској индустрији.

Вештачка интелигенција игра значајну улогу у обезбеђивању квалитета и контроли квалитета у аутомобилској индустрији и *Lean* индустријским системима. Она пружа напредне алате и технике које омогућавају ефикасно и прецизно праћење производних процеса, идентификацију дефекта и проблематичних области, као и предвиђање потенцијалних проблема.

Један од начина примене вештачке интелигенције у обезбеђивању квалитета је у области визуелне инспекције. Напредне методе компјутерског вида и алгоритми дубоког учења представљања омогућавају аутоматску анализу визуелних података и откривање недостатака на компонентама и производима (Слика 2.4-7)(Faragó et al., 2022). Ова техника може знатно смањити време испитивања, погрешно класификовање производа, и побољшати капацитет инспекције.



Слика 2.4-7 Шематски приказ детекције дефеката помоћу вештачке интелигенције (Lv et al., 2020)

Додатно, вештачка интелигенција може бити корисна у предвиђању квалитета производа. Уз помоћ алгоритама машинског учења и претходних података, систем може анализирати различите параметре производних процеса и предвидети вероватноћу дефекта или несавршености. Ово омогућава прецизно идентификовање проблематичних области и правовремено предузимање адекватних мера, што доприноси повећању ефикасности и смањењу грешака (Badora et al., 2021). У *Lean* индустријским системима, вештачка интелигенција може бити употребљена за анализу и оптимизацију производних процеса. Системи за надгледање и контролу могу да праћењем различитих параметара процеса и применом алгоритама машинског учења дају предлоге за унапређење ефикасности и смањење губитака. Такође, вештачка интелигенција може

обезбедити аутоматску проверу и исправљање грешака у процесу, што доприноси бољем квалитету производа и смањењу трошкова.

Може се закључити да интеграција вештачке интелигенције у систем квалитета у аутомобилској индустрији и *Lean* системима отвара врата новим могућностима и напретку. Ова технологија има потенцијал да смањи трошкове, побољша ефикасност и осигура конзистентност и квалитет производа. Са непрестаним напретком у области ВИ, можемо очекивати да ће ова технологија играти још већу улогу у будућности, пружајући нове могућности за обезбеђивање квалитета и контролу у индустрији.

На основу поређења недеструктивних метода испитивања квалитета, као што је и приказано у табели 2.4-1, може се закључити следеће: Ултразвучна провера се истиче као брза и неинвазивна метода са високом резолуцијом за детекцију унутрашњих дефеката. Међутим, она може бити ограничена на материјале са високом апсорпцијом и захтева постојање спојног медијума, а и непоуздана је за ситније дефекте. Испитивање помоћу магнетних честица се истиче као прецизна метода за детекцију унутрашњих дефеката са оценом величине и дубине. Међутим, зависи од магнетских карактеристика материјала, испитивани део може бити контаминиран честицама, а резултати могу бити подложни субјективним проценама. Пенетрантно тестирање има могућност квантитативне оцене карактеристика дефекта и примењиво је на различите материјале. Међутим, оно је временски захтевно и није адекватно за порозне материјале, и такође испитивани део може бити контаминиран пенетрантним супстанцама. Термографија пружа брзу и неинвазивну анализу топлотних аномалија са тродимензионалним приказом, али зависи од околних услова и носи значајне трошкове термографских камера и обуке оператера. Рендген и компјутерска томографија бесконтактно откривају дефекте и анализирају унутрашњу структуру објеката, али захтевају изложеност јонизујућем зрачењу, специфичну обуку, високе трошкове опреме и дуг период трајања испитивања и интерпретације резултата. Вештачка интелигенција представља брз и аутоматизован начин за анализу и откривање дефеката са ниским инвестицијама. Међутим, зависи од квалитета улазних подата података и обучавања алгоритама.

Табела 2.4-1. Преглед карактеристика неструктивних метода и њихове примене у области контроле квалитета

Назив методе	Област Примене	Предности	Недостаци
Ултразвучна провера	Квантитативна анализа дефеката, Контрола квалитета, Карактеризација материјала	* Брза детекција унутрашњих дефеката са високом резолуцијом. * Неинвазивна метода * Безбедно за оператере.	* Могућа некомпатибилност испитиваног материјала са методом провере. * Неопходност постојања спојног медијума * Непоузданост детекције дефеката мањих од 1мм
Испитивање помоћу магнетних честица	Идентификација и локализација дефекта, Оцена исправности компоненти, Контрола квалитета	* Прецизна детекција унутрашњих дефеката, оцена величине и дубине дефекта. * Променљивост на различите конфигурације и топологије објеката.	* Зависност од магнетичких карактеристика испитиваног материјала. * Могућност контаминације испитиваног дела. * Резултати подложни субјективној процени.
Пенетрантно тестирање	Процеси заваривања, Оцена квалитета површине, Идентификација дефекта	* Могућност квантитативне оцене карактеристика дефекта. * Применљивост на различите материјале.	* Временски захтевно. * Неадекватна метода за потповршинске дефекте. * Могућност контаминације испитиваног дела. * Зависност од подложности материјала, није адекватна метода за порозне материјале.
Термографија	Детекција грешака у електричним компонентама, Оцена ефикасности изолације	* Брза и неинвазивна анализа топлотних одступања. * Могућност тродимензионалног приказа. * Висок контраст за објекте различитих температура.	* Зависност од околних услова и околне температуре. * Значајна цена термографских камера. * Неопходност обученог кадра.
Рендген и компјутерска томографија	Медицинске дијагнозе, Контрола квалитета у ваздухопловној и аутомобилској индустрији	*Бесконтактно откривање дефеката и анализа унутрашње структуре објеката *Могућност тродимензионалног приказа *Детекција дефеката величине неколико стотина нанометара	*Експозиција на јонизујуће зрачење *Потребна специфична обука кадрова *Висока цена опреме *Дужина трајања испитивања *Дужина трајања интерпретације резултата
Вештачка интелигенција	Контрола квалитета производа, Инспекција компоненти, Аутоматско испитивање	*Брза анализа и откривање дефеката *Аутоматско бележење резултата испитивања *Релативно ниска инвестиција	*Зависност од квалитета обучавања алгоритма/модела, и квалитета података

3 Преглед литературе у подручју примене вештачке интелигенције у индустријском окружењу са фокусом на област контроле квалитета

Вештачка интелигенција показала је велики потенцијал у примени у различитим индустријским секторима. Један од најзначајнијих сектора у којима се примењује вештачка интелигенција је производна индустрија. Примена вештачке интелигенције у овом сектору може имати значајан утицај на производне процесе, квалитет производа, ефикасност и конкурентност компанија.

Ово поглавље приказује истраживање које се односи на примену вештачке интелигенције у индустрији, фокусирајући се на две области: примену вештачке интелигенције у индустрији и примену вештачке интелигенције у контроли квалитета. У првом делу, разматра се примена вештачке интелигенције у производној индустрији општег карактера, укључујући аутомобилску индустрију и друге сродне секторе. У овом делу, обрађују се различите области у којима се вештачка интелигенција може применити у производним процесима, као што су оптимизација производних процеса, управљање ланцем снабдевања, аутоматизација и подршка у одлучивању.

Други део поглавља фокусира се на примену вештачке интелигенције у контроли квалитета. Контрола квалитета је кључни аспект у производним процесима, а вештачка интелигенција може пружити нове могућности за побољшање и унапређење овог аспекта. Различите примене вештачке интелигенције у контроли квалитета обрађују се у овом делу, укључујући детекцију дефекта, класификацију и оцену квалитета, локализацију дефекта и аутоматску проверу квалитета.

Циљ овог поглавља је да пружи преглед примена вештачке интелигенције у производној индустрији и контроли квалитета, истичући предности и могућности које оне пружају. Кроз анализу различитих примера и студија случаја, обрађују се различите области примене вештачке интелигенције и њихов допринос усавршавању производних процеса и постизању високог квалитета производа.

Ово поглавље приказује значајне импликације за производне компаније, посебно у аутомобилској индустрији, које теже усавршавању производних процеса, повећању квалитета и ефикасности. Увођење вештачке интелигенције у производне процесе и контролу квалитета може допринети бржем и ефикаснијем току производње, побољшаном квалитету производа и смањењу трошкова.

У даљем тексту је дат списак појмова коришћених у оквиру стручне терминологије везане за вештачку интелигенцију и обучавање модела:

- **Машинско читање** -Преузимање, односно ишчитавање података из одређеног документа помоћу аутоматизованог софтверског решења
- **Улазни подаци** – Подаци који се користе као улазна информација за одређени процес
- **Излазни подаци** - Подаци који се добијају као излазна информација из одређеног процеса
- **Протокол** – Процедура којом је дефинисан одређени процес рада или испитивања
- **Стринг** - Тип података који представља низ текстуалних карактера
- **Преприлагођавање** – Тренирање модела вештачке интелигенције тако да он постаје превише прилагођен скупу података на ком је обучен, модел се превише компликује тако да почетне шумове и случајности у тренинг подацима посматра као знакове или обрасце, тако да постаје неприменљив на податке који су ван тренинг скупа

- **Подприлагођавање** - Модел је превише једноставан и не може ефикасно да се прилагоди тренинг подацима, што резултује лошим перформансама на оба, тренинг и тест скупу података
- **Неуронске мреже** - Математички модели инспирисани радом људског мозга, који се користе у машинском учењу за решавање различитих задатака
- **Алгоритми класификације и регресије** - Методе у машинском учењу које се користе за предвиђање категорије (класе) или вредности (регресије) на основу улазних података
- **Обрада природног језика (енг. *Natural Language Processing* - NLP)** - Област која се бави обрадом и анализом текстуалних података
- **Структура података** - Организација и уређење података који омогућавају ефикасну обраду и приступ
- **Претпроцесирање података** - Манипулација, анализа и обрада података ради припреме за извођења одређених задатака
- **Бајесове мреже** - Графички модели који користе Бајесове методе за моделирање вероватноће и зависности између различитих догађаја.
- **Распознавање облика (енг. *Pattern Recognition*)** - Процес идентификације и класификације образаца или структура у подацима
- **Функција грешке (енг. *Loss Function*)** - Мера колико је добро модел предвиђао излазне вредности у односу на тачне вредности у тренинг скупу
- **Градијентно спуштање (енг. *Gradient Descent*)** - Алгоритам који се користи за минимизацију функције грешке у машинском учењу
- **Аугментација података (енг. *Data Augmentation*)** - Процес додавања варијација или модификација у тренинг скуп података ради побољшања учења модела
- **Трансформација података (енг. *Data Transformation*)** - Процес промене формата или структуре података ради бољег разумевања или анализе
- **Функција активације (енг. *Activation Function*)** - Функција која се користи у неуронским мрежама за увођење нелинеарности у излазном слоју
- **Машински вид (енг. *Computer/Machine Vision*)** - Област која се бави разумевањем и анализом слика и видео снимака од стране рачунара
- **Стопа учења (енг. *Learning Rate*)** - Параметар који одређује колико брзо се модел учи током тренинга у машинском учењу
- **Хиперпараметар (енг. *Hyperparameter*)** - Параметар који се користи за конфигурацију алгоритма машинског учења или модела, али који није учен из података. Примери хиперпараметара укључују број и величину слојева у неуронским мрежама или вредности параметара у алгоритмима градијентног спуштања
- **Пондер (енг. *Weight*)** - У контексту неуронских мрежа, пондер представља тежину која се додељује вези између неурона у различитим слојевима мреже. Тежине се користе за оцењивање значајности улаза и регулисање учења мреже
- **Величина беча (енг. *Batch Size*)** - Број примерака података који се користе за тренирање модела у једној итерацији тренинга. Величина беча утиче на стабилност учења и брзину конвергенције алгоритма

- **Нод (енг. *Node*)** - Нод представља појединачни неурон у мрежи који обрађује улазне податке, израчунавајући тежинске суме и примењујући активациону функцију
- **Неурон (енг. *Neuron*)** - Основна јединица неуронске мреже која прима улазне податке, врши њихово обрађивање помоћу тежина и активационих функција, и генерише излаз. Неурони су основни градивни блокови неуронских мрежа
- **Перцептрон (енг. *Perceptron*)** - Једнослојна неуронска мрежа која се користи за класификацију. Он је најједноставнија форма вишеслојних перцептрона и састоји се од улазног слоја, излазног слоја и слоја тежина
- **Бекпропагација (енг. *Backpropagation*)** - Алгоритам који се користи за тренирање вишеслојних неуронских мрежа. Он се састоји из процеса преноса грешке уназад кроз мрежу, ажурирања тежина и оптимизације модела.

3.1 Различите примене вештачке интелигенције у индустрији

Вештачке интелигенција има широк спектар могућности за унапређење и оптимизацију производних процеса у различитим индустријским секторима. Од примене вештачке интелигенције у контроли квалитета и процесној оптимизацији до управљања ланцем снабдевања и подршке у одлучивању, ово потпоглавље истиче различите начине на које вештачка интелигенција може трансформисати и модернизовати индустријске процесе. Анализирају се студије случаја и примери из различитих индустријских сектора, пружајући увид у стварне примене и предности које вештачка интелигенција доноси у индустрију. Кроз истраживање различитих примена, циљ је да се истакну могућности и потенцијал који вештачка интелигенција нуди за модернизацију и напредак у индустрији и да се пруже упутства и примери за компаније које желе да искористе предности вештачке интелигенције и постигну конкурентску предност на тржишту.

Оптимизација производних процеса: Вештачка интелигенција има значајну улогу у оптимизацији производних процеса у различитим индустријским областима. Користећи алгоритме машинског учења и анализу великих скупова података, системи вештачке интелигенције могу аутоматски анализирати производне линије, идентификовати могуће слабости и препоручити ефикасније начине рада. Ово може укључивати оптимални распоред операција, управљање ресурсима и превазилажење проблема у реалном времену (Woschank et al., 2020). Резултат је повећање ефикасности, смањење трошкова и побољшање квалитета производа.

Могуће је користити вештачку интелигенцију у контексту паметне логистике зарад побољшања унутрашњег и спољашњег транспорта. Иако је примена технологија вештачке интелигенције, машинског учења и дубоког учења у контексту паметне логистике још у раној фази развоја, већина идентификованих студија се бави концептима, лабораторијским експериментима или су у веома раним фазама тестирања (Woschank et al., 2020). Зреле индустријске примене још увек недостају. Међутим, континуирано извештавање о поставкама машина, стању машина, подешавањима параметара квалитета, предиктивном одржавању, системима за подршку доношењу одлука, напредном распоређивању, планирању и контроли приступа у истраживачким пољима управљања залихама, проблема у процесу тока, традиционалних проблема распоређивања производње и унапређења оперативних логистичких процеса, као што су

приступу идентификацији и праћењу, могу се сматрати обећавајућим областима унутар оквира паметне логистике (Cioffi et al., 2020).

Предиктивно одржавање: Вештачка интелигенција игра кључну улогу у предиктивном одржавању машина и опреме у различитим индустријским областима. Користећи анализу података сензора, машинско учење и алгоритме предикције, системи вештачке интелигенције могу предвидети отказе и проблеме у опреми пре него што се они десе. На основу прикупљених података о стању опреме, интелигентни системи могу генерисати акције предупредјења, предложити оптималне планове одржавања и помоћи у планирању ресурса (Daniyan et al., 2020). Ово доводи до смањења времена застоја, економичнијег коришћења ресурса и повећања доступности и радне ефикасности опреме.

Предиктивно одржавање помоћу вештачке интелигенције постаје снажан алат за производне компаније. Користећи алгоритме вештачке интелигенције, компаније могу анализирати велике количине података о стању машина, сензорским информацијама и историјским подацима о одржавању. На основу ових података, модели вештачке интелигенције могу предвидети време и вероватноћу дефеката компоненти или отказа машина (Zonta et al., 2020). Ова предиктивна информација омогућава компанијама да планирају одржавање унапред, избегну неочекиване кварове и смањење времена прекида производње.

Примена вештачке интелигенције у предиктивном одржавању укључује и различите технике машинског учења, као што је анализа аномалија. Компаније могу тренирати моделе вештачке интелигенције да препознају необичне обрасце и одступања у раду машина. Када се детектују аномалије, систем може генерисати аларме или упозорења, што омогућава тимовима одржавања да одреагују пре него што се проблеми погоршају (Matzka, 2020).

Вештачка интелигенција може такође бити укључена у мониторинг и анализу више параметара машина. Закључује се да компаније могу користити вештачку интелигенцију за анализу великог броја сензорских података и идентификацију корелација између различитих параметара, што им омогућава да предвиде стање машина и процеса. На основу тих предикција, тимови одржавања могу планирати рутинска одржавања или поправке у складу са стварним потребама.

Интеграција вештачке интелигенције у системе предиктивног одржавања омогућава и побољшану оптимизацију резервних делова и потреба за одржавањем. вештачке интелигенције може анализирати историјске податке о кваровима и поправкама, проценити учесталост и вероватноћу неуспеха за сваки део, и предложити оптимални инвентар резервних делова (Zonta et al., 2020). Ово помаже компанијама да минимизирају трошкове складиштења и набавке делова, истовремено осигуравајући доступност неопходних делова када су им потребни.

Примена вештачке интелигенције у предиктивном одржавању у производној индустрији има значајан потенцијал да побољша ефикасност, смањи трошкове и повећа доступност и радно време машина (Cardoso and Ferreira, 2020). Интеграција вештачке интелигенције у предиктивно одржавање представља нову еру у менаџменту одржавања.

Управљање ланцем снабдевања је једно од подручја у којима вештачка интелигенција има значајну примену. Велики скупови података и комплексност процеса у ланцу снабдевања захтевају аутоматску анализу, предикцију и оптимизацију. Вештачка интелигенција се може користити за прогнозирање потреба, управљање складиштима, оптимално планирање и рутинске операције. Интелигентни системи могу анализирати податке о наручивању, логистици, растеретити рачунарску комплексност и допринети оптималном раду ланца снабдевања (Helo and Hao, 2022).

Примена вештачке интелигенције у управљању ланцем снабдевања може донети значајне предности, укључујући повећану ефикасност, смањене трошкове и побољшано праћење и контролу процеса. На пример, вештачка интелигенција може анализирати велике количине података о потрошњи, производњи, складиштењу и превозу како би предвидео потребе за снабдевањем и оптимизовао распоред и доставу робе (Riahi et al., 2021). Ово помаже компанијама да уштеде време и ресурсе, смање варијације и побољшају испоруку крајњим корисницима.

Вештачка интелигенција може бити укључена у праћење и управљање инвентаром. Користећи алгоритме машинског учења, вештачка интелигенција може предвидети потребу за инвентаром на основу историјских података, потрошње и сезонских фактора (Pournader et al., 2021). То омогућава компанијама да наставе снабдевање у складу са потребама без прекомерног складиштења и сметања.

Анализа података и предикција тржишних трендова је још једна важна примена вештачке интелигенције у управљању ланцем снабдевања. Компаније могу користити алгоритме вештачке интелигенције да анализирају велике количине података о потрошњи, куповним навикама, друштвеним медијима и другим релевантним факторима (Тоогајроур et al., 2021). На основу ових анализа, вештачка интелигенција може предвидети трендове потрошње и помоћи компанијама у планирању производње и расподели ресурса.

Управљање ризиком и превазилажење проблема у ланцу снабдевања је још један аспект где вештачка интелигенција може бити корисна. Компаније могу користити алгоритме вештачке интелигенције за детекцију и управљање ризицима као што су кашњење испорука, квалитет производње, неспособност добављача и сл. (Belhadi et al., 2021). Такође, вештачка интелигенција може помоћи у превазилажењу проблема у ланцу снабдевања кроз брзу анализу и аутоматско предлагање алтернативних решења.

Примена вештачке интелигенције у управљању ланцем снабдевања у производној индустрији пружа многе могућности за оптимизацију и побољшање ефикасности. Од аутоматизованог управљања инвентаром до предвиђања тржишних трендова, вештачка интелигенција помаже компанијама да преузму интелигентне и информисане одлуке у ланцу снабдевања и да остваре конкурентску предност.

Роботика и аутоматизација се јединствено спајају са вештачком интелигенцијом у постизању напредних нивоа аутоматизације у индустрији. Развој аутономних робота са напредним системима вештачке интелигенције омогућава њихову употребу у различитим задацима у производњи, монтажи, паковању и складиштењу. Роботи могу самостално процесирати информације, прилагођавати се променама и оптимизовати перформансе (Vrontis et al., 2022). Ово доприноси повећању производне ефикасности, смањењу грешака и повећању безбедности на радном месту. Роботи са више-сензорским системима и алгоритмима вештачке интелигенције могу извршавати различите задатке у производњи, као што су складиштење, манипулација делова, монтажа и паковање (Vrontis et al., 2022). Вештачка интелигенција омогућава роботима да уче из искуства, адаптирају се на промене у окружењу и донесу самосталне одлуке.

Један од примера примене вештачке интелигенције у роботизи је колаборативна роботика, где роботи раде у тиму са људима (Sharma, 2023). Користећи алгоритме вештачке интелигенције, роботи могу детектовати и пратити покрете радника, предвидети њихове намере и прилагодити своје активности да би били безбедни и ефикасни у заједничком раду. Ово омогућава већу безбедност и ефикасност на радном месту.

Управљање комплексним производним системима је још једна област у којој вештачка интелигенција има значајну улогу. Роботи и аутоматизовани системи могу бити оптимизовани помоћу алгоритама вештачке интелигенције како би се постигла

боља расподела рада, побољшала координација и смањили прекиди у производњи (Wang and Siau, 2019). Ово помаже компанијама да повећају производну ефикасност, смање трошкове и повећају квалитет производа.

Употреба вештачке интелигенције у роботизи такође обухвата учење робота из демонстрација. Користећи алгоритме машинског учења, роботи могу учити из примера и потом применити стечено знање у реалном окружењу (Ribeiro et al., 2021). Ово им омогућава да се брзо адаптирају на нове задатке, непознате околности и раде са већом генерализацијом.

Примена вештачке интелигенције у роботизи и аутоматизацији производне индустрије је наставак напретка и еволуције унапређења производних процеса. Вештачка интелигенција помаже роботима да постану интелигентнији, побољшавају ефикасност и квалитет у производњи и да се прилагоде на променљиве услове радног окружења.

Подршка у одлучивању може бити омогућена применом вештачке интелигенције. Користећи алгоритме машинског учења и анализу података, системи вештачке интелигенције могу обрадити огромне количине информација и предложити најбоља решења. Они могу предвидети трендове, идентификовати шансе и ризике, анализирати тржиште и конкуренцију (Araujo et al., 2020). Ова технологија помаже менаџерима и водећим особама у доношењу бољих и интелигентнијих одлука.

Вештачка интелигенција може бити корисна у подршци одлучивању у производној индустрији кроз различите аспекте, укључујући планирање, прогнозирање, анализу података и оптимизацију (Duan et al., 2019). На пример, алгоритми вештачке интелигенције могу анализирати историјске податке о производњи, потрошњи, тржишту и другим релевантним факторима како би предвидели будуће трендове и донели интелигентне одлуке у вези са производњом, складиштењем и дистрибуцијом (Ding et al., 2020).

Подршка одлучивању помоћу вештачке интелигенције укључује и различите алгоритме машинског учења, који могу учити из података и предвидети оптималне одлуке. На пример, вештачка интелигенција може применити алгоритме класификације и регресије да би предвидела најбоље одлуке у вези са планирањем производње, дистрибуцијом производа и управљањем залиха. Ово помаже компанијама да смање трошкове, повећају ефикасност и постигну боље резултате.

Аутоматско одлучивање је још један аспект где вештачка интелигенција може бити примењена у производној индустрији. Користећи алгоритме вештачке интелигенције, компаније могу развити системе који самостално доносе одлуке на основу постављених критеријума и променљивих услова. На пример, системи за управљање квалитетом могу користити вештачку интелигенцију да донесу одлуке о прихватању или отпаду производа на основу анализе квалитетних параметара и стандарда (Shrestha et al., 2019). Вештачка интелигенција може бити корисна и у симулацијама и оптимизацији производних процеса. Компаније могу користити алгоритме вештачке интелигенције да промене поставке производне линије, редослед операција и параметре како би постигли најбољу ефикасност и резултате. Ово им омогућава да експериментишу са различитим сценаријима и предвиде како би најбоље оптимизовали своје производне процесе.

Примена вештачке интелигенције у подршци одлучивању у производној индустрији доприноси повећању прецизности, ефикасности и унапређењу процеса одлучивања. Одлуке засноване на алгоритмима вештачке интелигенције омогућавају компанијама да постигну оптималне резултате у производњи, управљању залихама и дистрибуцији, што им пружа конкурентску предност на тржишту (Shrestha et al., 2019).

Управљање енергијом може бити знатно ефикасније и ефективније уз примену вештачке интелигенције. Користећи податке о потрошњи енергије, временским прогнозама и системима управљања, системи вештачке интелигенције могу оптимизовати употребу енергије. Они могу аутоматски регулисати осветљење, грејање и климатизацију у зградама и индустријским постројењима, пратити потрошњу енергије и предлагати начине за ефикасније коришћење ресурса. Овај приступ доприноси смањењу трошкова и негативног утицаја на животну средину (Yu et al., 2021).

Један од примера примене вештачке интелигенције у енергетском менаџменту је прогнозирање потрошње енергије. Користећи алгоритме машинског учења, вештачка интелигенција може анализирати историјске податке о потрошњи енергије и спољних фактора, као што су температура и сезонски услови, како би се предвидела будућа потрошња (Yu et al., 2021). Ово помаже компанијама да планирају и оптимизују употребу енергије, смањују трошкове и постигну већу енергетску ефикасност.

Додатни пример је управљање енергетским системима у реалном времену. Алгоритми вештачке интелигенције могу надгледати рад енергетских система и динамички контролисати потрошњу енергије. На пример, алгоритми усмерени управљања могу регулисати рад осветљења, грејања и хлађења у производним процесима на основу тренутних услова и предвиђања (Yu et al., 2021). Ово помаже уштеди енергије и смањује утицај на животну средину.

Додатна примена вештачке интелигенције у енергетском менаџменту је оптимизација дистрибуције енергије. Компаније могу користити алгоритме вештачке интелигенције за оптимално усмеравање енергије на различите делове производних процеса. На пример, вештачка интелигенција може анализирати реалну потребу за енергијом у различитим деловима производне линије и регулисати расподелу енергије да би се минимизовали губици и повећала ефикасност (Ali and Choi, 2020).

Примена вештачке интелигенције у енергетском менаџменту у производној индустрији има потенцијал да смањи трошкове, повећа енергетску ефикасност и смањи негативан утицај на околину. Интелигентни системи управљања енергијом на бази вештачке интелигенције омогућавају компанијама да се баве променљивим захтевима енергије и да донесу ефикасне одлуке за оптимално коришћење енергетских ресурса.

Логистика: Вештачка интелигенција има значајну улогу у логистици. Користећи анализу великих скупова података и алгоритме машинског учења, системи вештачке интелигенције могу предвидети потребу за материјалима и резервним деловима, планирати оптималне руте транспорта, и пратити ток робе у реалном времену (Woschank et al., 2020). Ово доприноси смањењу трошкова, побољшавању ефикасности и сигурности у логистичким операцијама.

Праћење и управљање складиштем се може унапредити помоћу вештачке интелигенције. Кроз анализу података о залихама, потражњи и понуди, вештачка интелигенција може предвидети оптималне нивое залиха, локацију складишта и распоред складиштених производа (Pandian, 2019). Ово помаже компанијама да смање губитке, побољшају ток робе и повећају ефикасност операција складиштења.

Трасирање и распоређивање транспорта се може оптимизовати помоћу вештачке интелигенције у производној индустрији. Кроз анализу података о расположивим возилима, путањама, временским условима и другим факторима, алгоритми вештачке интелигенције могу предвидети оптималне руте, распоред испорука и ресурсе потребне за транспорт (Chien et al., 2020). Ово помаже компанијама да смање трошкове транспорта, побољшају тачност испорука и смање време путовања.

Вештачка интелигенција се може користити за оптимизацију временских рокова и приоритизацију у логистици у производној индустрији. Кроз анализу података о роковима испоруке, расположивим ресурсима, капацитетима производње и другим

факторима, алгоритми вештачке интелигенције могу донети одлуке о оптималном распореду производње и испоруке, узимајући у обзир хитност и важност сваког наруџбеног захтева (Chung, 2021).

Примена вештачке интелигенције у логистици у производној индустрији доноси бројне предности, укључујући смањење трошкова, повећање ефикасности, оптимизацију ресурса и побољшање услуге купцима. Компаније које успешно користе вештачку интелигенцију у логистичким процесима имају конкурентску предност на тржишту и могу постићи боље резултате у погледу испоруке и задовољства купаца.

Безбедност и здравље на раду се може значајно унапредити применом вештачке интелигенције. Примене вештачке интелигенције у безбедности и здрављу на раду у производној индустрији може донети значајне предности, укључујући смањење ризика од повреда, побољшање радног окружења и очување здравља радника. Кроз интеграцију технологија вештачке интелигенције и система за управљање безбедношћу, компаније могу створити безбедно и здраво радно окружење, повећати ефикасност производње и постићи боље резултате у погледу безбедности и здравља на раду.

Рано откривање ризика и спречавање повреда је од велике важности, нарочито у индустријском окружењу. Вештачка интелигенција се може користити за анализу података о радним условима, физичким оптерећењима и другим факторима ризика како би се препознали потенцијални ризици и преузели превентивни кораци. На пример, алгоритми вештачке интелигенције могу анализирати сензорске податке са радних места како би идентификовали неправилности у покретима радника или опасне услове који би могли довести до повреда (Fallah Madvari, 2023). На основу тих информација, могу се предузети мере за побољшање безбедности и смањење ризика од повреда.

Праћење здравља радника се може знатно олакшати применом вештачке интелигенције. Кроз анализу података о физиолошким параметрима, као што су параметри тријаса, ниво стреса и ниво умора, вештачка интелигенција може препознати знакове замора или исцрпљености код радника (Todolí-Signes, 2021). На основу тих информација, могу се предузети превентивне мере, као што су редовни одмори или прерасподела послова, како би се очувало здравље и спречиле озбиљније здравствене проблеме.

Аутоматизовано управљање опасним материјалима може значајно смањити ризик, и могућност незгода у производној индустрији. Алгоритми вештачке интелигенције могу анализирати податке о врстама материјала, њиховим карактеристикама и безбедносним прописима како би их аутоматски препознали и применили одговарајуће мере предострожности (Yonebayashi et al., 2021). На пример, вештачка интелигенција може следити складиштење и транспорт опасних материјала, идентификовати потенцијалне ризике или неправилности и предузети акције за спречавање евентуалних несрећа или инцидента.

Заштита животне средине потпомогнута вештачком интелигенцијом у производној индустрији кроз бројне примере примене показује како технологија може бити корисна у смањењу негативних утицаја на животну средину и унапређењу одрживости. Кроз ефикасније управљање ресурсима, оптимизацију процеса и доношење информисаних одлука, вештачка интелигенција помаже да се постигне равнотежа између производње и заштите природе. Системи вештачке интелигенције могу анализирати податке о потрошњи енергије, емисији штетних материја и прогнозировать енергетске потребе. Вештачка интелигенција такође може помоћи у праћењу и контроли важних параметара животне средине, као што су квалитет ваздуха, воде и отпада.

Вештачка интелигенција се користи за ефикасно управљање отпадом и рециклажом у производној индустрији (Abdallah et al., 2020). Алгоритми вештачке интелигенције могу анализирати податке о врстама отпада, количини, карактеристикама

и могућностима рециклаже. На основу тих података, могу се донети одлуке о оптималном третману отпада, идентификовати могућности за рециклажу и смањити количину отпада која завршава на депонијама. Ово доводи до смањења негативног утицаја на животну средину и промовисања одрживости.

Вештачка интелигенција се може користити за праћење квалитета воде и ваздуха у производној индустрији. Алгоритми вештачке интелигенције могу анализирати податке о загађењу, концентрацијама штетних материја и другим параметрима квалитета. На основу тих података, могу се идентификовати области са високим нивоом загађења, препознати узроци и предложити мере за смањење загађења (Zhao et al., 2020). Ово помаже у заштити природних ресурса и очувању здравља људи и екосистема.

Алгоритми вештачке интелигенције могу анализирати податке о доступним путевима, саобраћајним условима, емисијама возила и другим факторима. На основу тих података, могу се пронаћи оптималне руте које минимизирају емисије гасова стаклене баште или смањују време путовања (Мао et al., 2019). Ово доприноси смањењу негативних утицаја транспорта на животну средину и промовисању одрживе мобилности.

Евалуација купчевих захтева у ауто индустрији може изискивати пуно времена. Примена вештачке интелигенције у оквиру ауто индустрије омогућава евалуацију купчевих захтева на ефикасан и прецизан начин. Вештачка интелигенција, кроз употребу алгоритама машинског учења и дубоког учења, може аутоматски обрадити велику количину података о купцима, њиховим захтевима, историји евалуације различитих захтева купаца итд. На основу ових података, вештачка интелигенција може извршити анализу и прецизну евалуацију купчевих захтева, што омогућава компанијама у ауто индустрији да боље разумеју потребе својих купаца и да им понуде адекватна решења без ризика од обавезивања нереалним захтевима. Оваква примена вештачке интелигенције за евалуацију купчевих захтева може допринети побољшању купчевог искуства, повећању задовољства купаца и јачању позиције компанија у ауто индустрији.

Контрола квалитета може користећи технике машинског учења и компјутерског вида, системе вештачке интелигенције и др. аутоматски анализирати визуелне и сензорске податке за идентификацију мана, дефекта или несавршености у производима. Ово може обухватати проверу димензија, облика, боје, текстуре и других критеријума квалитета. Предности овог приступа укључују бржу и прецизнију контролу, смањење људског фактора и побољшање квалитета производа и процеса.

3.2 Примена вештачке интелигенције у контроли квалитета

Вештачка интелигенција је револуционисала начин на који индустрија функционише, и има потенцијал да трансформише процес контроле квалитета у аутомобилској индустрији. Коришћењем техника машинског учења (МУ) и дубоког учења (ДУ), вештачка интелигенција може аутоматизовати контролу квалитета, смањити производне трошкове и побољшати квалитет производа. У овом сегменту ће бити описане различите индустријске примене вештачке интелигенције у контроли квалитета са фокусом на аутомобилску индустрију. Аутомобилска индустрија је позната по строгим захтевима у контроли квалитета, а вештачка интелигенција може помоћи да се ови стандарди испуне ефикасније. Вештачка интелигенција се може користити за аутоматизацију задатака контроле квалитета, као што су откривање, класификација, локализација дефеката, итд. Алгоритми машинског учења могу учити на основу претходних података како би идентификовали дефекте, док алгоритми ДУ могу побољшати прецизност учењем на великим скуповима података. Вештачка

интелигенција има значајну улогу у контроли квалитета у производњи у аутомобилској индустрији. Системи вештачке интелигенције могу надгледати и анализирати различите параметре производног процеса, као што су температура, притисак, брзина и други сензорски подаци. На основу тих података, системи вештачке интелигенције могу идентификовати потенцијалне аномалије у процесу и преносити информације оператерима или управљачким системима за брзу реакцију и исправку. Ово помаже у осигуравању постизања жељеног квалитета производа.

Откривање дефеката Откривање дефеката је важан део контроле квалитета у аутомобилској индустрији. Вештачка интелигенција може детектовати дефекте на компонентама коришћењем техника обраде слика. Анализирајући слике компоненти, вештачка интелигенција може идентификовати дефекте који су невидљиви људском оку. Ово може помоћи у побољшању укупног квалитета производа и смањењу броја дефеката.

Аутоматизована детекција дефеката на основу компјутерског вида добила је велику пажњу у различитим индустријским областима где се захтева квалитетна контрола површина. У последњим годинама, истраживачи су развили различите технике и методологије за детекцију дефеката помоћу вештачке интелигенције, укључујући машинско учење, дубоко учење и компјутерски вид.

Истраживачи су извршили обухватну анализу технологија за аутоматско откривање дефеката на површини челичних производа, прегледавши 120 публикација из периода од претходне две деценије. Резултати сугеришу на четири категорије методологија (статистичке, спектралне, моделске и методе машинског учења) и пружају препоруке за имплементацију и будућа истраживања (Luo et al., 2020). Ови приступи имају за циљ побољшање квалитета контроле површина и смањење грешака које би иначе прошле неконтролисано. Истраживачи и инжењери имају могућност да искористе ове напредне технике за унапређење својих процеса контроле и осигурања квалитета у својим индустријским областима.

Класификација дефеката на основу њихове озбиљности и типа се може извршити помоћу вештачке интелигенције. Ово може помоћи у приоритизацији дефеката који треба прво решити, као и идентификацији узрока дефекта. На пример, ако се исти тип дефекта понавља, вештачка интелигенција може помоћи у идентификацији узрока проблема, омогућавајући компанијама да реше проблем у самом корену.

Класификација дефекта на површини различитих материјала представља изазован задатак у производној индустрији. У последње време, вештачка интелигенција игра значајну улогу у решавању овог проблема. Конкретно, конволуцијске неуронске мреже (CNN) се истичу као ефикасна техника за класификацију дефекта на основу слика (Fu et al., 2019). Поменути студија представља лак и брз модел конволуцијске неуронске мреже за аутоматско препознавање дефеката на површини челика. Користећи пред-тренирану SqueezeNet архитектуру, метод достиже високу тачност при класификацији дефеката на тестном скупу који укључује изазовне услове за класификацију. Лак модел који ради у реалном времену са преко 100 fps на рачунару са једном NVIDIA TITAN X графичком обрадном јединицом (12GB меморије) (Fu et al., 2019). Овакви модели имају способност да уче из великог броја тренинг примера и препознају различите типове дефекта, као што су оштећења, неисправности или несавршености на површини. Коришћењем вештачке интелигенције за класификацију дефекта, производне компаније могу значајно повећати ефикасност и прецизност својих система контроле квалитета. Овакви приступи могу бити примењени у различитим индустријским областима, укључујући челичну, електронску, аутомобилску и др. Класификација дефекта помоћу вештачке интелигенције има потенцијал да смањи могућност за настанак грешке и ризик

од несавршености у производним процесима, доводећи до побољшања квалитета производа и задовољства купаца.

Локализација дефеката такође може бити унапређена помоћу вештачке интелигенције. Ово може помоћи произвођачима да идентификују узрок дефекта и одреде најбољи начин за решавање проблема. Локализацијом дефеката, произвођачи такође могу смањити количину материјала који мора бити одбачен, што смањује производне трошкове.

Са напредовањем вештачке интелигенције, локализација дефеката постала једна од примарних примена у производној индустрији. Иновативне технике локализације дефеката помоћу вештачке интелигенције пружају могућност прецизног и брзог откривања дефеката на различитим производима (Нао et al., 2021). У поменутом истраживању, развијен је модел за инспекцију површина челика који користи напредне технике за детекцију објеката. Мрежа са деформабилним конволуцијама издваја детаље дефеката, док мрежа за спајање особина генерише високо-квалитетне мапе особина за инспекцију дефеката различитих величина (Нао et al., 2021). Детекторска мрежа обезбеђује локализацију и класификацију дефеката, а модел показује високу тачност и ефикасност на испитиваном скупу података.

Једна од таквих примена је детекција дефеката на површини каросеријских панела аутомобила. Алгоритми вештачке интелигенције могу анализирати слике каросеријских панела како би детектовали површинске дефекте као што су огреботине, удубљења и корозија. Ово може помоћи у побољшању укупног квалитета производа и смањењу броја дефеката. На пример, у оквиру инспекције површине челика, модели засновани на дубоком учењу користе се за издвајање и анализу особина дефектних области. Ово омогућава да се локализују и идентификују дефекти, као што су огреботине, оштећења и неуједначена боја. Применом вештачке интелигенције у локализацији дефеката, производне компаније могу ефикасније и брже утврдити проблематична подручја и предузети потребне корективне мере. Овај напредак у области локализације дефеката помаже у подизању квалитета производа и повећавању ефикасности производних процеса.

Аутономни системи инспекције могу анализирати слике компоненти и детектовати дефекте без интервенције човека. Ово може помоћи у смањењу времена и трошкова повезаних са људском визуелном инспекцијом, као и побољшању тачности процеса инспекције. Аутономна инспекција помоћу вештачке интелигенције представља значајну технику за унапређење процеса инспекције у различитим индустријским областима. Истраживачи истичу примену вештачке интелигенције за аутономну инспекцију различитих компоненти и структура (Fotouhi et al., 2021). У овом истраживању, истраживачи су применили дубоко учење за квантитативну оцену видљивости различитих типова оштећења на композитним структурама, као што су авионске и ветро-турбинске лопатице. Коришћена је обимна база података са сликама која обухвата различите механизме оштећења на микро и макро нивоу. Путем претрениране верзије АлексНет мреже, обављена је аутоматска класификација типова и озбиљности оштећења, а резултати су показали висок степен тачности (87%–96%) у разумном временском оквиру (Fotouhi et al., 2021). Ова студија представља значајан допринос у области аутономне визуелне инспекције композитних структура са потенцијалом за смањење трошкова, и повећање прецизности и тачности испитивања.

Уместо традиционалног људског, визуелног приступа, аутономни системи користе различите алгоритме и технике вештачке интелигенције, укључујући дубоко учење и компјутерски вид, за прецизну детекцију и класификацију дефекта. Овај приступ омогућава брзу и ефикасну инспекцију, смањујући време и ресурсе потребне за ручну проверу. Аутономна инспекција помоћу вештачке интелигенције пружа

могућност за рано откривање дефекта, што доприноси повећању квалитета производа и смањењу грешака у производњи.

Анализа сигнала и сензорска обрада се може извршити помоћу вештачке интелигенције у реалном времену. Ово омогућава брзо и прецизно откривање аномалија или неусаглашености у квалитету производа, што доводи до брзе интервенције и смањења грешака (Pimenov et al., 2023).

Вештачка интелигенција се широко примењује у области анализе сигнала и сензорске обраде у индустријским окружењима. Коришћењем алгоритама машинског учења и дубоког учења, системи вештачке интелигенције могу обрадити и интерпретирати велику количину сигнала и сензорских података у реалном времену (Andronie et al., 2021). Ово им омогућава да открију скривене обрасце и неусаглашености које би могле утицати на квалитет производа.

Примена вештачке интелигенције у анализи сигнала и сензорској обради омогућава брзо откривање аномалија и неусаглашености, што омогућава оператерима и техничарима да на време реагују и предузму потребне мере. На пример, системи засновани на методама вештачке интелигенције могу аутоматски детектовати неисправности у сензорима или неочекиване промене у сигналу, што може упозорити на могуће проблеме у производном процесу (Pimenov et al., 2023). Такође, системи вештачке интелигенције могу пратити и анализирати различите параметре квалитета производа, што омогућава да се идентификују и реше потенцијални проблеми у раној фази производње. У поменутом раду се истражују тенденције у вези са носивошћу алатних инструмената и аспектима машинске обраде, с фокусом на мониторинг стања алатних инструмената користећи нове сензоре и вештачку интелигенцију. Размотрени су различити типови сензора и методи вештачке интелигенције, као што су неуронске мреже, фази логика, и препознавање слика, са нагласком на њихове предности, недостатке и перспективе у пракси, пратећи холистички приступ овој области (Pimenov et al., 2023).

Примена вештачке интелигенције у анализи сигнала и сензорској обради представља значајан напредак у области квалитета у индустријским окружењима. Она доприноси повећању ефикасности, смањењу грешака и побољшању квалитета производа, што има дугорочне бенефите за компаније и потрошаче.

Предикција: Вештачка интелигенција се користи за класификацију и предвиђање квалитета производа на основу унапред тренираних модела. Ово омогућава препознавање потенцијалних проблема или недостатака, како би се превентивно преузеле одговарајуће акције и спречио губитак квалитета.

Примена вештачке интелигенције у квалитету има значајну улогу у предикцији дефеката у индустријским окружењима. Уместо деструктивних тестирања, која могу бити скупа и временски захтевна, развијени су модели предикције помоћу метода машинског учења (Рајић et al., 2023a). У истраживању су развијена 4 предиктивна модела машинског учења, на малим скуповима података у контексту отпорничког лемљења бакарних контаката. Иако је мали број улазних података био доступан, а број негативних улазних вредности мањи од 2%, студија демонстрира успешно обучавање модела и његову примену у предвиђању исхода тестова. Овакви модели могу бити економична алтернатива деструктивним тестовима, обучавани на основу мањих скупова података, што је чест случај у индустријским окружењима где је доступност података ограничена, што доприноси смањењу трошкова и утрошеног времена.

У истраживањима, као што је представљено у овом раду, методологија се обично састоји од скупа фаза које укључују прикупљање и припрему података, анализу корелације, избор карактеристика, тренирање модела, оптимизацију хипер параметара и

евалуацију модела. Кључно је да квалитет података буде задовољавајући како би модел могао да предвиди резултате тестова са задовољавајућом тачношћу (Рајић et al., 2023a).

Примена модела предикције дефеката помоћу вештачке интелигенције има бројне предности у индустријским окружењима. Осим смањења трошкова тестирања, овакав приступ такође омогућава брже и ефикасније процесе квалитетне контроле. Напредак у овој области отвара могућности за унапређење квалитета производа и оптимизацију производних процеса у индустрији.

Колаборативни работи управљани помоћу вештачке интелигенције у индустријским окружењима постају суштински значајни у области контроле квалитета. Колаборативни работи омогућавају безбедну и ефикасну сарадњу између робота и радника у процесу контроле квалитета. Они су способни да извршавају комплексне задатке, раде у условима који су неприступачни или опасни за људе, и олакшавају монотоне задатке (Brito et al., 2020). Истраживачи су анализирали примену колаборативних робота у контексту 4. индустријске револуције за подршку интелигентној инспекцији и корективним мерама у системима контроле квалитета у производном процесу. Описан је иновативан приступ у коме колаборативни робот, обучен подржаним учењем, извршава дефинисане задатке контроле квалитета. Овакав систем постаје робуснији кроз учење и прилагођавање свог понашања у складу са задацима инспекције различитих делова. У претходним експериментима, *UR3* робот са *Force-Torque* сензором успешно је извршавао све дефинисане задатке контроле квалитета производа (Brito et al., 2020).

Комбинација вештачке интелигенције и колаборативних робота у контроли квалитета представља значајан напредак у производној индустрији, пружајући повећану ефикасност, прецизност и безбедност. Овај приступ омогућава компанијама да постигну висок квалитет својих производа и унапреде своју конкурентност на тржишту. Ослањајући се на потенцијал вештачке интелигенције и колаборативних робота, индустријски сектор може значајно унапредити процесе контроле квалитета и осигурати конзистентно висок квалитет производа.

Машински вид је постао значајна технологија у области инспекције дефеката производа. Примена вештачке интелигенције у машинском виду омогућава рачунарима да анализирају и процењују визуелне податке са великом брзином и прецизношћу. У процесу инспекције дефеката производа, системи вештачке интелигенције могу детектовати и класификовати различите типове дефеката као што су огреботине, пукотине, корозија, оштећења, лоше наливање лепка, контаминације, лоше позициониране компоненте и друге несавршености (Рајић et al., 2023b). Истраживачи су у овом раду усмерили своје напоре на унапређење старих визијских система за откривање дефеката на штампаним електронским плочама. Доказано је да је могуће унапредити постојеће системе користећи вештачку интелигенцију, без потребе за заменом камера. Основна предност овог приступа огледа се у смањењу лажно детектованих дефеката и скраћењу времена подешавања надзорног система (Рајић et al., 2023b).

Користећи напредне алгоритме машинског учења и дубоког учења, системи вештачке интелигенције могу препознати и најмање дефекте са великом прецизношћу (Wang et al., 2019). Овај приступ у визијској инспекцији дефеката производа нуди брзу и ефикасну методу за контролу квалитета, олакшавајући процес производње и смањујући могућност не детекције дефеката. Предности машинског вида за инспекцију дефеката производа су брзина, прецизност и побољшана ефикасност у производном окружењу.

3.3 Практични примери примене вештачке интелигенције

Машинско учење представља један од сегмената вештачке интелигенције, који има за циљ да машинама омогући да самостално донесу одлуке на основу улазних података и информација о ограничењима. Постоји неколико различитих приступа машинском учењу, укључујући надгледано, ненадгледано и учење подстицајем (Bishop, 2006).

Надгледано машинско учење се заснива на обезбеђивању базе података са јасним критеријумима и класификованим обележеним информацијама. На пример, потребно је да машина раздваја метални новац динарске валуте по вредности. Машини ће се пружити информација о тежини кованица различитих вредности (јасан критеријум) и податак о тежини сваке појединачне кованице. Битно је уочити да ће се мерењем тежине кованица добити свега неколико различитих вредности које су унапред познате. Упоређивањем измерене вредности са дефинисаним вредностима може се лако идентификовати свака кованица.

Код ненадгледаног машинског учења нема обележених информација нити јасних критеријума. Може се размотрити ситуација у којој машину треба обучити да класификује метални новац различитих валута и апоена. Овде је немогуће припремити базу података која би укључивала све могуће кованице, јер би она била превелика и компликована за ажурирање. Уместо тога, ненадгледано машинско учење може обезбедити податке о кластерима кованица различитих тежина, што олакшава анализу и класификацију.

Машинско учење подстицајем представља комбинацију претходне две методе, пружајући систему могућност да кроз повратну информацију коригује свој алгоритам (Bishop, 2006). На пример, машину можемо обучити да идентификује различите валуте и апоене на основу препознавања облика кованица. Томе би претходило пружање различитих критеријума и граничних вредности које би машина упоређивала са контролисаном кованицом. У процесу "едукације", машини би експерт пружао повратну информацију о тачности пружених резултата, чиме би се систем калибрисао и унапредио своју способност за класификацију.

Користећи ове различите приступе машинском учењу, могуће је успешно идентификовати и класификовати кованице различитих валута и апоена у аутомобилској индустрији, што значајно доприноси повећању ефикасности и тачности у раду.

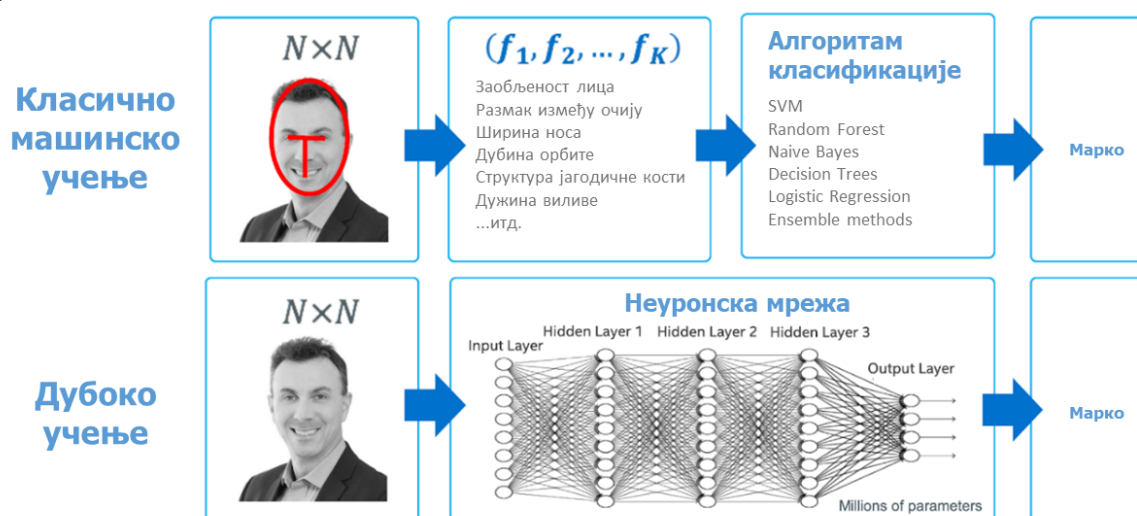
Надгледано машинско учење је приступ који се заснива на обележеним подацима и подразумева пружање јасних критеријума којима се дефинише излаз за сваки улазни податак. На пример, ако је потребно обучити модел за класификацију слика мачака и паса, потребно је креирати базу слика мачака и паса за које су јасно обележене класе (мачка или пас). Након обуке модела са оваквим обележеним подацима, он ће бити способан да класификује нове, непознате слике мачака и паса.

Ненадгледано машинско учење, са друге стране, користи необележене податке и не пружају му се јасни критеријуми класификације. На пример, ако се узме велика база текстуалних докумената и потребно је груписати сличне документе, али не постоји обележје који документ припада којој групи, то би био пример ненадгледаног машинског учења. Модел би тражио сличности и облике у подацима, без експлицитних инструкција.

Постоје предности и недостаци обе методе. Надгледано машинско учење омогућава високу тачност и ефикасност у класификацији, али захтева велику базу обележених података који могу бити скупи и временски захтевни за сакупљање, филтрирање и обраду. С друге стране, ненадгледано машинско учење захтева мање времена за припрему података, али може бити мање прецизно у класификацији.


Кроз ове примере, уочава се да обе методе имају своје предности и могу се користити у различитим контекстима. Надгледано машинско учење је погодно када постоји квалитетна база обележених података и желе се тачни и прецизни резултати класификације. Ненадгледано машинско учење је употребљиво када не постоје обележени подаци или је потребно истражити необележене структуре и односе у подацима. Коришћењем обе методе, машине унапређују своју способност за доношење одлука на основу података, што је од изузетног значаја у многим областима и пружа могућности за револуционарне примене вештачке интелигенције.

Насупрот машинском учењу, дубоке неуронске мреже не захтевају обележене податке, нити дефинисане критеријуме (Слика 3.3-1). Код дубоког учења је довољно обезбедити машини пар фотографија субјекта којег је потребно препознати, док је код машинског учења неопходно идентификовати критеријуме и доделити им одговарајуће вредности.



Слика 3.3-1 Упоредни поједностављени приказ процеса препознавања лица конвенционалном методом машинског учења, и методом дубоког учења (Robins, 2020)


Дубоке неуронске мреже се заснивају на математичким функцијама и теорији вероватноће (Heaton and Heaton, 2013). Најосновнији приступ дубоког учења при доношењу одлуке ће због комплексности процеса бити објашњен на примеру графичког приказа који се састоји од свега 4 пиксела црне или беле боје. Задатак алгоритма вештачке интелигенције би овде био да одреди боју пиксела и њихову оријентацију, односно да одлучи да ли је графика једнобојна, или се пиксели налазе у вертикалној, хоризонталној или дијагоналној оријентацији. Прилично једноставна графика и прилично једноставан задатак. Уколико се претпостави да пиксели могу бити различитих нијанси, свакој нијанси спектра између црне и беле би се могла доделити нумеричка вредности. Нпр. потпуно црн пиксел би добио вредност -1, сиви пиксел вредност 0 и потпуно бео вредност +1 (Слика 3.3-2).



Слика 3.3-2 Графички приказ превођења боје пиксела у нумеричку вредност, додељивање пондера и сумирање вредности у позитрону (лево) и нормализација вредности помоћу сигмоидне функције (десно)(Rohrer, 2021)

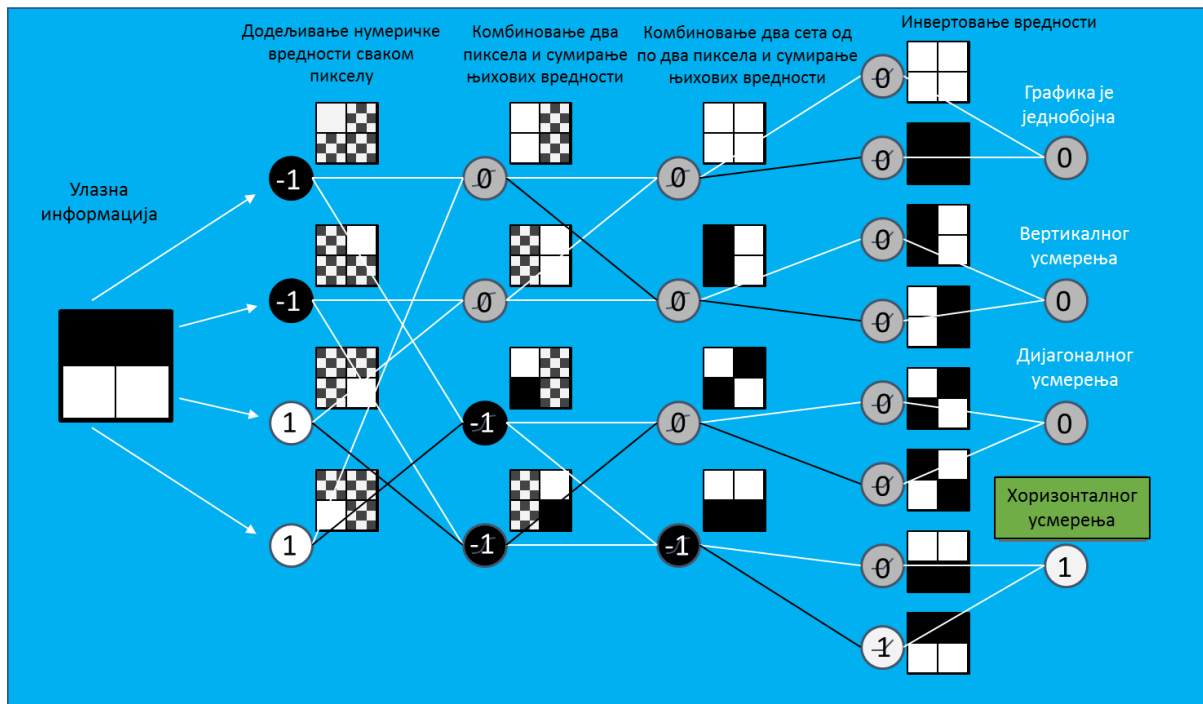
У улазним неуронима би била изражена ова нумеричка вредност сваког појединачног пиксела. Пре слања информације у унутрашње слојеве неуронске мреже, овим вредностима се додељује пондер (тежина) у распону -1 до +1. Додељивање пондера се може вршити насумично или помоћу алгоритма али то у овом тренутку није пресудно за разумевање концепта дубоке неуронске мреже (Heaton and Heaton, 2013). У првом унутрашњем слоју неуронске мреже се израчунава сума свих производа улазних вредности помножених са додељеним пондером. У зависности од броја улазних информација, њихових вредности и додељених тежина нумеричка вредност у првом неуронском слоју може излазити из распона -1 и +1. Пошто је тај распон погодан за даље калкулације, помоћу сигмоидне функције се добијене вредности нормализују и свде на распон од -1 до +1 (слика 3.3-2) (Heaton and Heaton, 2013).

Такође је могуће елиминисати негативне вредности помоћу ReLU методе (Слика 3.3-3) (Heaton and Heaton, 2013). Инвертовање вредности ReLU методом, како је и приказано на графикону, је конципирано тако да се све позитивне вредности задржавају, а негативне приказују као нула.




Слика 3.3-3 Инвертовање вредности ReLU методом, позитивне вредности се задржавају а негативне приказују као нула (Rohrer, 2021)

Упрошћен пример је графика која има 4 пиксела који могу бити само потпуно црни или потпуно бели, и потребно је одредити њихов распоред унутар графике (Слика 3.3-4). У улазном сету неурона се сваком појединачном пикселу додељује нумеричка вредност, црни пиксел -1, а бели пиксел +1. Може се доделити и пондер у овом кораку али није нужно. Такође је могуће помоћу сигмоидне функције извршити нормализацију вредности, у овом примеру то није урађено. У другом слоју неурона се комбинују два пиксела и израчунава се њихова вредност. У трећем сету неурона се комбинују два сета од по два пиксела и израчунава се њихова вредност. У четвртном слоју неурона се преузимају подаци из претходног слоја и врши се инвертовање вредности. У излазном слоју се сумирају вредности парова (инвертована и не инвертована вредност) па се као резултат добија нумеричка вредност. На овом примеру се може закључити да ће резултат са највећом вредношћу бити најтачнији. Ова хипотетичка ситуација је постављена у складу са анализом литературе (Heaton and Heaton, 2013) и графичких приказа преузетих са интернета (Rohrer, 2021).




Слика 3.3-4 Графички приказ дубоке неуронске мреже која има задатак одређивања оријентације пиксела дате графике (Rohrer, 2021)

У излазном слоју вредности често нису прецизно одређене, одлука није тако очигледна као у наведеном примеру, те је потребна обука модела вештачке интелигенције. У фази обуке је могуће пружити алгоритму информацију који одговор је тачан тако да алгоритам може доделити другачије пондере различитим инпутима (Heaton and Heaton, 2013). Мерење удаљености и смера тачног резултата даје податак на који начин је потребно кориговати пондере. У овом примеру се може претпоставити да су пондери додељени у првој итерацији. То се може видети на примеру (Слика 3.3-5), где се у излазном слоју неурона добија резултат. Нетачни одговори имају у колони „истина“ вредност 0, а тачни одговори вредност 1. Колона „грешка“ исказује удаљеност вредности тачних одговора и добијених резултата вероватноће за тачан одговор. У овом тренутку алгоритам врши корекцију пондера и добија се нови резултат. Тада се може израчунати промена грешке из тренутне и претходне итерације, и поделити са променом вредности пондера из тренутне и претходне итерације (Слика 3.3-5). На овај начин се добија информација да ли пондер за дати резултат треба повећати или смањити.



Слика 3.3-5 Графички приказ утицаја вредности пондера на тачност добијеног резултата (лево), и табела са вредностима и формула за израчунавање нагиба (десно) (Rohrer, 2021)

Битно је напоменути да су ови примери дубоких неуронских мрежа изузетно упрошћени и да само осликавају поједностављени приступ вештачке интелигенције у процесу одлучивања. Неуронске мреже дубоког учења могу имати огроман број улазних информација као и огроман број неурона у унутрашњим слојевима. На донекле сличном принципу функционише и људски мозак, где неурони стварају синапсе са другим неуронима (Azizi, 2019). Синапсе у људском мозгу су неуронске везе које омогућавају проток информација између неурона. Ове везе се развијају у зависности од учесталости комуникације између неурона - што је комуникација чешћа, смањује се електро отпорност између два неурона, те везе постају јаче (Слика 3.3-6) (Ou et al., 2022). У одређеном контексту би се јаче синапсе могле поистоветити са већим пондером.



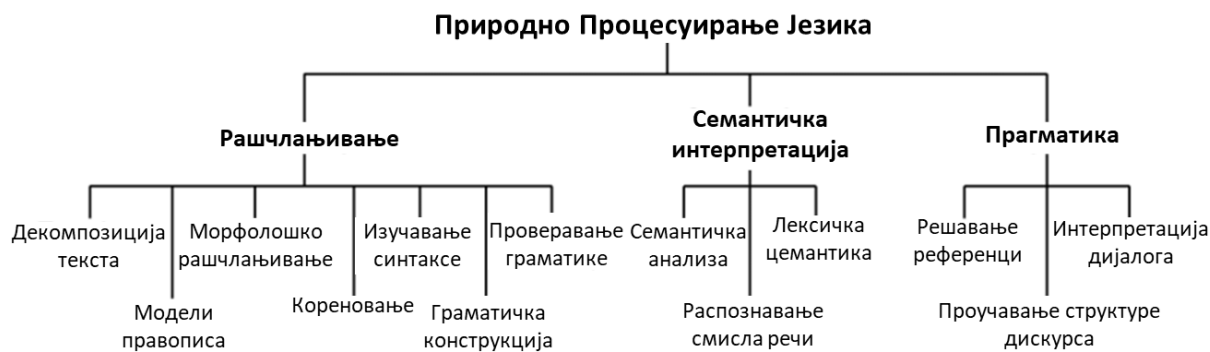
Слика 3.3-6 Графички приказ неуронске мреже људског мозга и неуронске мреже вештачке интелигенције (Talin, n.d.)

Још један значајан сегмент вештачке интелигенције је природно процесирање језика. Да би машине разумеле текст, потребно им је прво разумети слова. Код електронских текстуалних докумената је то знатно једноставније док се за писани текст

може користити напреднији облик вештачке интелигенције за препознавање облика. Зарад лакшег разумевања, и у складу са темом рада, биће описан само приступ евалуацији електронских текстуалних докумената. Да би алгоритам препознао слово, потребно је сваком слову доделити нумеричку вредност. Како би се упростио процес, може се свакој речи доделити нумеричку вредност (Sparck Jones and Galliers, 1995). Ово би имало предност над словном нумерацијом, јер би се нпр. речи ЈА могла доделити нумеричка вредност 001. Тако би се за ту нумеричку вредност могла узети информација да је то именица, класификацијом нумеричких вредности у бази података (Sparck Jones and Galliers, 1995). Разумљиво је да би база података морала бити обимна. Обзиром да су купчеви захтеви углавном на енглеском језику, разматраће се случај базе података за само један језик. Када би свака реч у енглеском језику добила своју нумеричку вредност и класификацију према врсти речи, било би потребно дефинисати оквире за конструкцију реченица. Нпр. алгоритам би се могао конструисати да препознаје правилан редослед речи у реченици, правилно слагање времена, морфологију речи итд. (Слика 3.3-7). Како је описано код машинског учења, едукација машине може бити надгледана, ненадгледана и подржана. Речи ипак саме по себи често немају стриктно, већ флексибилно, значење. Нпр. реч дрво се може односити на врсту материјала, живи организам или једноставно грану на стази за трчање. Речи добијају значење стављањем у одређени контекст, односно окруживањем другим речима. Ако би се започела реченица и препустило вештачкој интелигенцији да је настави, претрагом разних текстова и база података алгоритам може пронаћи речи које се најчешће користе у комбинацији са датим речима и обезбедити одређене предлоге (Sparck Jones and Galliers, 1995). Корисничким усвајањем или одбијањем понуђених предлога (нпр. код *Google* претраге), алгоритам калибрише пондере и учи уз корисника (Sankar et al., 2020). Насупрот овом примеру генерисања текста, при разумевању текста приступ би био другачији. Један од приступа би био:

- Лексичка анализа
- Синтаксичка анализа
- Семантичка анализа
- Контекстна анализа
- Прагматичка анализа

Лексичка анализа би обухватала анализу структуре речи и фраза које би се упоређивале са базама података/речницима у оквиру датог језика. Синтаксичка анализа је проучавање узајамних односа речи у реченици, као и правила која одређују низање реченица у следовима (Lensu, 2002). Семантичка анализа идентификује значење речи у складу са дефиницијом датих речи у речнику и њиховим положајем и међусобним односом са осталим речима у реченици. Контекстна анализа узима у обзир значење претходних реченица и у складу са тим предвиђа значење анализиране и наредне реченице. Прагматичка анализа се фокусира на значење текста у одређеној комуникацији у односу на намере и улоге учесника (Lensu, 2002).



Слика 3.3-7 Различити аналитички процеси при природном процесуирању језика (Lensu, 2002)

Мора се разумети да процес едукације система вештачке интелигенције може трајати одређено време, пар сати до пар месеци, за стварање услова за иницијално покретање система у зависности од његове комплексности (Sankar et al., 2020).

3.4 Примери метода и алгоритама машинског учења погодних за мале скупове података

При избору метода машинског учења за мале скупове података, важно је разматрати алгоритме који су робусни и способни да обраде ограничене количине информација. Међу погодним методама спадају алгоритми класификације и регресије као што су линерна регресија, и стабла одлучивања (Rodriguez-Galiano et al., 2015). Ови методи захтевају мање података за тренирање и могу ефикасно радити и са малим скуповима података. Поред тога, технике преносивог учења (transfer learning) и аугментација података (data augmentation) могу бити корисне за унапређење перформанси и ефикасности учења на малим скуповима података.

Линеарна регресија је једноставна и ефективна метода машинског учења. Осим тога, добро се може применити на мале скупове података, а њени резултати могу бити интуитивно тумачени (Jiang, 2021). Уопштено, ако постоји сумња у бар приближну корелацију између две карактеристике у популацији, линеарна регресија се може користити за истраживање и спецификацију те корелације. У ту сврху, две интересне карактеристике X и Y се тестирају на објектима из популације (Hartung et al., 2005). $2n$ реализација x_1, \dots, x_n и y_1, \dots, y_n ће се користити за истраживање линеарне везе како је приказано у једначини 1:

$$y = \alpha + \beta x_i + e_i \text{ for } i = 1, \dots, n \quad \text{Једначина (1)}$$

Где је α апсолутни члан, а β нагибни параметар линеарне везе. Као што је горе поменуто, често постоје неуспеси или обманљиве информације у подацима, описане као шум. Параметар e_1, \dots, e_n представља шум у овој једначини (Hartung et al., 2005). Да би се одредиле тачке процене a и b за параметре α и β у проблему линеарне регресије, на такав начин да се одреди најбоља могућа процена \hat{y} за израз y карактеристике Y , који има израз x карактеристике X , користи се регресивна линија приказана у једначини 2:

$$\hat{y} = a + bx \quad \text{Једначина (2)}$$

Најбоља могућа процена y за израз карактеристике \hat{y} , који има израз карактеристике X , се одређује (Hartung et al., 2005). Као критеријум за квалитет процене користи се сума квадрата одступања као мера, како је приказано у једначини 3:

$$R^2 = \sum_{i=1}^n (y_i - a - bx_i)^2 \quad \text{Једначина (3)}$$

Проценитељи a и b за α и β морају се одредити на такав начин да сума R^2 вертикалних квадрата одступања измерених вредности y од пружених вредности за x на регресивној линији $y_i - a - bx_i$ минимизује. Овај метод се назива метод најмањих квадрата (Galos et al., 2021). Псеудо код за линеарну регресију приказан је у алгоритму 1 као пример.

Алгоритам 1 Псеудо код за линеарну регресију (Strehl and Littman, 2007)

0: **Inputs:** α, β

1: Иницијализуј $x = [x_1, \dots, x_n]$ and $y = [y_1, \dots, y_n]$ и број опсервација n .

2: Израчунај $S_x = \sum_{i=1}^n x_i$ and $S_y = \sum_{i=1}^n y_i$

3: Иницијализуј збир производа x и y S_{x*y}

4: Иницијализуј збир квадрата x S_{x*x}

5: **for** $I = 1, 2, 3, \dots : n$ **do**

6: Израчунај S_{x*y} as $S_{x*y} = \sum_{i=1}^n x_i * y_i$

7: Израчунај S_{x*x} as $S_{x*x} = \sum_{i=1}^n x_i * x_i$

8: Израчунај β as $\beta = \frac{(n*S_{x*y} - S_x*S_y)}{(n*S_{x*x} - S_x*S_x)}$

9: Одреди средње вредности $meanX$ and $meanY$

10: Израчунај α as $\alpha = meanX - \beta * meanY$

У Алгоритму 1, $x = [x_1, \dots, x_n]$ представља вредности независне променљиве, $y = [y_1, \dots, y_n]$ представља вредности зависне променљиве; S_x је сума свих вредности посматране независне променљиве x ; S_y је сума свих вредности посматране зависне променљиве y на нивоу сваког посматрања i ; $S_{(xx)}$ је сума свих квадратираних вредности посматране независне променљиве x на нивоу сваког посматрања i ; $S_{(xy)}$ је сума свих производних вредности посматране независне променљиве x и зависне променљиве y на нивоу сваког посматрања i , α је процењени пресек а β је процењени нагиб.

Random Forest и **Gradient Boosted Trees** припадају моделима заснованим на стаблима. Обе методе комбинују резултате појединачних стабала одлучивања. На основу евалуације неуронских мрежа, случајних шума, регресивних стабала и методе подршке вектора, алгоритми засновани на стаблима одлучивања показују лакшу примену у тренингу (Rodriguez-Galiano et al., 2015). Главна предност **Gradient Boosted Trees** је метода појачавања (енг. *boosting*), која секвенцијално комбинује слаба стабла одлучивања, тзв. Слабије ученике, тако да се у новом стаблу одлучивања исправљају грешке претходних стабала. Још једна предност је избегавање преприлагођавања учењем на једноставним скуповима података, с обзиром да слабији ученици не хватају све комплексне динамике у подацима. У неким случајевима, с обзиром на табеларне податке, методе надгледаног учења, попут **Gradient Boosted Tree** регресије, чак надмашују популарне методе дубоког учења (Shwartz-Ziv and Armon, 2021). У Алгоритму 2 је приказан псеудо код за Gradient boosted tree као пример.

Алгоритам 2 Псеудо код за Gradient boosted tree (Qi et al., 2018)

- 1: **Inputs:** $D = \{(x_1, y_1), \dots, (x_N, y_N)\}$, θ , γ
- 2: **Output:** $F(x) = \sum_{i=0}^M F_i(x)$
- 3: Иницијализуј $F_0(x) = \arg \min_{\beta} \sum_{i=0}^N L(y_i, \beta)$
- 4: **While** ($m < M$)
- 5: $d_i = -[\partial L(y_i, F(x_i)) / \partial F(x_i)]$ $F(x_i) = F_{m-1}(x_i)$
- 6: $\mathfrak{D} = \{(x_i, d_i)\}$, $i = 1, N$
- 7: $g(x) = \text{FITREGRETREE}(\mathfrak{D}, \theta)$
- 8: $\rho_m = \arg \min_{\rho} \sum_{i=1}^N L(y_i, F_{m-1}(x) + \rho g(x))$
- 9: $F_m(x) = F_{m-1}(x) + \gamma \rho_m g(x)$
- 13: **End while**

У методи Случајна шума (енг. *Random Forest*), граде се различита стабла одлучивања и комбинују се паралелно. У поређењу са другим техникама машинског учења, за Случајну шуму су потребна само два параметра за генерисање модела: број регресивних стабала и број карактеристика које се разматрају (Jiang, 2021). Смањење броја карактеристика доводи до смањења корелације између стабала и повећања тачности модела (Rodriguez-Galiano et al., 2015). Псеудокод за методу Случајна шума приказан је као пример у Алгоритму 3.

Алгоритам 3 Псеудо код за Random Forest (Guo и сар., 2021)

- 1: За генерисање c класификатора:
- 2: **For** $I = 1$ to c **do**
- 3: Насумично одабери податке за тренинг D са заменама да се добије D_i ,
- 4: Направи коренски нод, N_i који садржи D_i
- 5: Позови функцију Build Tree (N_i)
- 6: **End for**
- 7: **Build Tree (N):**
- 8: **If** N садржи инстанце само једне класе **then**
- 9: **Return**
- 11: **Else**
- 12: Насумично одабери $x\%$ од могућих карактеристика дељења у N
- 13: Изабери карактеристику F са највишим приносом информација за дељење
- 14: Направи f дете нод од N , N_i, N_j , где F има f могућих вредности (F_1, \dots, F_f)
- 15: **For** $I = 1$ to f **do**
- 16: Направи садржај N_i до D_i , где D_i представља све инстанце N које одговарају F_i
- 17: Позови функцију Build Tree (N_i)
- 18: **End for**
- 19: **End If**

Kernel Ridge Regression, такође позната као *Kernel Ridge Squares*, узета је у обзир као још један модел машинског учења, с обзиром на мали број резултата деструктивних тестова који су били доступни (Stulp and Sigaud, 2015; Zhang and Ling, 2018). Ова метода користи предност функције језгра (енг. *kernel*), која пројектује скуп података у више димензиони простор трансформишући карактеристике скупа података. Основна идеја која стоји иза преношења скупа података у више димензиони простор трансформацијом оригиналних карактеристика је реорганизација геометрије оригиналних карактеристика како би се добила једноставнија геометрија карактеристика скупа података (Jung, 2022). Два разматрана језгра су линеарно језгро и језгро радијалне базне функције. Надаље, *Kernel Ridge Regression* је нелинеарни облик регресије са регуларизацијом која спречава

преприлагођавање (Vu et al., 2015). У алгоритму 4 је приказан псеудо код за *Kernel Ridge Regression*.

Алгоритам 4 Псеудо код за Kernel Ridge Regression (Liu et al., 2022)

0: **Input:** сачуване популације претходних временских корака $\{P^1, P^2, \dots, P^t\}$, $P_k = \{v_{ij}^k \mid 0: i=1, 2, \dots, N; j=1, 2, \dots, d; k=1, 2, \dots, t\}$;
 0: **Output:** иницијална популација новог временског корака $P^{t+1} = (v_1^{t+1}, \dots, v_N^{t+1})$.;
 1: **for** $i=1, \dots, N$ **do**;
 2: **for** $j=1, 2, \dots, d$ **do**
 3: генериши временски серијал $s = (v_{ij}^1, v_{ij}^2, \dots, v_{ij}^t)$ из сачуваних популација;
 4: Добијање узорака тренинга од s користећи технику клизећег прозора;
 5: користи узорке тренинга да обучиш KRR модел;
 6: подеси инстанце тестова $x^{t+1} = (v_{ij}^{t-q+1}, \dots, v_{ij}^t)$;
 7: предвиди вредност ознаке (v_{ij}^{t+1}) тест инстанце; према $y^T (K + \alpha I_q)^{-1} k$ изведено од (Liu et al., 2022)
 8: поправи v_{ij}^{t+1} ако је изван граничних вредности према [4];
 9: **end for**
 10: **end for**

Опис логике одабраних метода машинског учења и оправданости примене описан је у табели 3.4-1 по узору на слична поређења других истраживача (Šušteršič et al., 2020).

Табела 3.4-1 Опис логике одабраних метода машинског учења и оправданости примене

Назив методе	Логика методе	Оправданост примене
Линеарна регресија	Линеарна регресија моделира однос између независних променљивих и зависне променљиве као линеарну комбинацију тих променљивих.	Једноставна је за имплементацију и интерпретацију, што је корисно за почетну анализу података. Погодна је за проблеме где се претпоставља линеарна веза између променљивих.
Random Forest	Random Forest је метода која користи више стабала одлучивања, где свако стабло добија случајни узорак података и предвиђања се агрегирају (нпр. већинско гласање за класификацију).	Робустан је према претренираности и добро функционише са малим скупом података јер свака шума учи из различитих узорака. Добро се носи са нелинеарним односима и високодимензионалним подацима.
Gradient Boosted Trees	Gradient Boosted Trees је метода која гради низ стабала одлучивања, где сва нова стабла покушавају да исправе грешке претходних стабала, користећи градијентни спуст за минимизацију губитка.	Има висок степен тачности и може се добро прилагодити малим скуповима података са неравнотежом класа, јер се сва нова стабла фокусирају на податке које претходна стабла нису добро предвидела.
Kernel Ridge Regression	Kernel Ridge Regression комбинује Ridge регресију са kernel методама омогућавајући нелинеарно мапирање података у вишедимензионални простор где се примењује линеарна регресија.	Погодна је за проблеме са малим скупом података и нелинеарним односима. Kernel трикови омогућавају моделирање комплексних образаца у подацима.

4 Развој и имплементација система за контролу квалитета у индустрији 4.0 у Lean индустријском окружењу, уз примену вештачке интелигенције

Ово поглавље описује истраживање фокусирано на интеграцију вештачке интелигенције у процесе контроле квалитета у оквиру Индустрије 4.0. Фокусиран на *Lean* индустријско окружење, рад примењује напредне методе машинског учења и машинског вида за предвиђање и детекцију дефеката у различитим производним процесима. Циљ дисертације је повећање ефикасности и квалитета производње, као и смањење трошкова и утрошеног времена у процесима контроле квалитета.

Поглавље обрађује различите примене вештачке интелигенције у обезбеђењу квалитета производа као што је приказано на Слици 4-1. Први део поглавља фокусира се на примену модела машинског учења за предвиђање исхода процеса лемљења у аутомобилској индустрији. Користећи мале скупове података, развијају се модели који доприносе унапређењу квалитета и ефикасности лемљења, а метода је заснована на регресионим моделима.

Други део поглавља обухвата примену машинског вида за класификацију и детекцију дефеката при наливању лепка за спајање елемената у аутомобилској индустрији. Путем развоја и тренирања модела, омогућено је брже и ефикасније откривање дефеката у спајању и спречавање додатних неусаглашености у производњи, а метода се заснива на класификацији и распознавању облика.

Трећи део поглавља истражује могућности примене вештачке интелигенције у евалуацији купчевих захтева у аутомобилској индустрији. Применом различитих алгоритама машинског учења, омогућава се ефикаснија анализа купчевих захтева и бржа обрада уговора, што доприноси смањењу ризика при потписивању обавезујућих докумената као и уштеди времена евалуатора, а метода је заснована на обради природног језика.

Четврти део поглавља истражује могућности примене вештачке интелигенције у обезбеђењу квалитета ласерски заварених спојева. Разматрају се конвенционалне методе контроле и системи паметног обезбеђивања квалитета, укључујући надзор сигнала процесних сензора помоћу вештачке интелигенције. Применом нових технологија и метода, доприноси се унапређењу квалитета ласерских заварених спојева и смањењу грешака у производњи.

Ова дисертација пружа нове увиде у примену вештачке интелигенције у контроли квалитета у оквиру индустрије 4.0. Кроз иновативан приступ и практичне примере, представљени су нови резултати и савремене методе које би могли значајно утицати на напредак у области контроле квалитета у индустријским окружењима.



Слика 4-1 Шематски приказ структуре анализе примене вештачке интелигенције кроз практичне и концептуалне примере (израдио аутор)

Истраживачке методе се односе на процес прикупљања, анализе, и интерпретације података како би се одговорило на постављена истраживачка питања и хипотезе. Истраживачке методе заступљене у овом поглављу се свode на експерименталне и студије случаја. Студије случаја укључују детаљно проучавање поменутих примена вештачке интелигенције у *Lean* индустријским системима за потребе управљања квалитетом и описује конкретизоване изазове, процесе и хипотетичке или реалне резултате примене решења. Експериментална методологија обухвата контролисане практичне експерименте примене поменутих решења заснованих на вештачкој интелигенцији и укључује контролисане тестове, манипулацију променљивама, статистичку анализу резултата и друго.

4.1 Примена модела машинског учења на мале скупове података за предвиђање исхода процеса лемљења у аутомобилској индустрији

У последњим деценијама, примена вештачке интелигенције у различитим областима привлачи велику пажњу научне заједнице и индустрије. Њена снага у обради великих количина података и анализи сложених узорака пружа нове могућности за унапређење контроле квалитета у различитим индустријским гранама. Од великог значаја је примена вештачке интелигенције у индустријским процесима, где може бити искоришћена за предвиђање неуспешних операција и откривање аномалија у производном процесу.

У овом сегменту дисертације, специфични фокус је на примени вештачке интелигенције у контроли квалитета операције лемљења бакарних намотаја на фазни прстен статора електромотора. Ово је критичан корак у производњи електромотора, а квалитетно лемљење је од виталног значаја за функционисање мотора са високом ефикасношћу. Постојеће методе контроле квалитета у овом сегменту се често ослањају на деструктивне тестове, који су не само скупи сами по себи, већ и захтевају уништење дела који ће бити коришћен у процесу тестирања. Зато развој предиктивног модела помоћу вештачке интелигенције носи велики потенцијал, јер може омогућити боље планирање, смањење отпада и ефикасније коришћење ресурса у производњи.

Предложени модел вештачке интелигенције у овом раду користи значајну количину реалних података о операцијама лемљења бакарних намотаја, а користе се конволуцијске мреже и алгоритми учења подстицајем да би се модел обучио да препозна аномалије и предвиди успешност операције лемљења. Ово представља важан корак у напретку контроле квалитета, јер се предвиђањем исхода операције у реалном времену избегавају потенцијалне неусаглашености и грешке у производњи. Осим тога, овај модел може бити проширен на друге сличне операције у производњи електромотора и других производа, што га чини универзалним и корисним алатом у индустријским окружењима.

4.1.1 Разматрања студије случаја

Када је реч о квалитету, безбедности производа и поузданости, аутомобилска индустрија се може сматрати једном од најзахтевнијих од свих индустрија (Bergmann et al., 2007). У непоузданим или ризичним производним процесима, неопходно је тестирати сваку компоненту. Ако је процес производње стабилан, поновљив и репродуктиван, али је повезан са неком посебном карактеристиком производа, може се применити статистичка контрола процеса (СКП) (Kumratı et al., 2021). Сви тестови не додају вредност производу, што повећава трошкове производње. Уколико су тестови деструктивни, то значи да се производ губи у току тог теста, што додатно повећава трошкове. Неки деструктивни тестови су захтевани од стране купаца, неки су неопходни како би се добио бољи увид у квалитет процеса и/или подешавали параметри производње, а неки деструктивни тестови су повезани са посебним карактеристикама које носе висок потенцијални ризик (Siwies and Pasana, 2021). Деструктивно тестирање захтева обучено особље, скупу опрему, време и материјале, и наравно производ који треба уништити (Maev et al., 2021).

Ова студија је фокусирана на реални пројекат замене деструктивних тестова моделом машинског учења за предвиђање исхода операције, у оквиру верификације процеса лемљења, у фабрици једног од врхунских снабдевача аутомобилске индустрије.

У овој студији, СКП је представљена кроз деструктивно тестирање статора електричне машине, ради верификације квалитета залемљеног контакта између бакарног намотаја и фазног прстена статора. Проучавани производ је трофазни статор електричне машине који је део погонске групе хибридног аутомобила, са бакарним намотајима који су лемљени на фазне прстенове (Слика 4.1.2-1). Описани тест користи насумично изабран статор из процеса производње, ради оцене квалитета залемљеног контакта и потребне силе при кидању контакта. Статор се сече, а лемљени контакти се одвајају. Неки од залемљених контаката се користе за тестирање силе кидања, а неки се брусе, полирају и прегледају под микроскопом (Слика 4-3). Под микроскопом се анализирају ширина и висина попречног пресека залемљеног споја, и траже се пукотине и шупљине у материјалу. Ови тестови се користе као начин статистичке контроле процеса и метод за одобравање производње при почетку рада.

Електрична и хибридна возила имају све већи удео на тржишту, зато је производња електричних погонских система постала све важнија (Husain et al., 2021). Електрични погони могу бити доста скупи, стога деструктивно тестирање може донети значајне непотребне трошкове. Замена деструктивних тестова алтернативним методама које не уништавају производ може довести до значајне уштеде трошкова. Што је процес производње стабилнији, мање компоненти треба испитивати. У фази имплементације нових пројеката, фреквенција тестирања мора бити висока док не буде довољно података да се установи да ли је процес поуздан или не. Такође, деструктивни тест СКП не може гарантовати да 100% произведених производа испуњава спецификације. Такође, у тесту описаном у овој студији, сече се пресек контакта и посматра се под микроскопом, што се може лако урадити на пределу контакта без дефекта на дефектном контакту, што неисправно класификује дефектни производ као део без дефеката. Имајући у виду све ове ограничења деструктивног тестирања СКП, потребно је пронаћи боље решење.


4.1.2 Опис процеса лемљења и деструктивног тестирања залемљених спојева

На Слици 4.1.2-1 је приказан трофазни статор електричног погона са 24 бакарна намотаја који су чврсто залемљени (отпорничко лемљење) на трофазне бакарне прстенове. Тврдо лемљење је скуп процеса код којих се материјали за лемљење загревају на температуре преко 450°C (изнад температуре топљења лемљеног материјала) (Jovanović and Lazić, 2015; Sevryukov et al., 2015).

Постоје четири основне технике загревања код лемљења (Jovanović and Lazić, 2015; Weis et al., 2017):


1. ручно лемљење лампом или гориоником,
2. индукционо лемљење,
3. отпорничко лемљење и
4. вакумско лемљење.

Отпорничко лемљење се ретко помиње у савременој научној литератури. Већина истраживачких радова у последњих неколико година била је усмерена на напредак у области залемљених материјала за тврдо лемљење, лемљење различитих материјала и нове методе за коришћење постојеће технологије лемљења (Sevryukov et al., 2015; Weis et al., 2017). У овом раду фокус је на Cu-Cu отпорничком лемљењу са основним, често коришћеним, залемљеним материјалима (Слика 4.1.2-1).



Слика 4.1.2-1 Графички приказ статора и залемљених контаката на трофазним прстеновима (Chen et al., 2009))

Глава за лемљење састоји се од 2 лемне сонде које могу појединачно да се померају по Z оси. Бакарне жице се постављају на фазни прстен који већ садржи интегрисан додатни лемни материјал, а кроз сонде се пропушта струја. Због загревања услед електричне отпорности и силе притиска, додатни материјал се топи, жица се шири, и обезбеђује се чврста веза између жица и фазног прстена, као што је приказано на Слици 4.1.2-2.




Слика 4.1.2-2 Шематски приказ процеса лемљења са микроскопским приказом попречног пресека области лемљења (Моокат, 2019))

Уколико параметри процеса лемљења нису правилно подешени, постоји ризик од формирања гасних мехурића, који могу довести до празнина у залемљеној области; такође могу настати пукотине; жица се може смањити или остати лоше причвршћена, а може се јавити и велики број других недостатака. Проблеми сличне врсте могу се јавити ако је област лемљења контаминирана. Овакви недостаци могу значајно утицати на топлотну и електричну проводљивост залемљеног контакта, као и на његову дуготрајност и поузданост (Wankerl et al., 2020).

Тренутно деструктивно тестирање подразумева сечење појединачних залемљених контаката ради прегледа под микроскопом (Слика 4.1.2-3). Мери се висина и дужина пресека жице и испитују се било какви недостаци, као што су поре или пукотине. У последње 3 године, у извештајима о квалитету производње у фабрици где је пројекат спроведен, пукотине и празнине су детектоване у мање од 1% узорак тестова

СКП и мање од 0.000003% свих произведених делова, зато се ова студија фокусира на предвиђање ширине и висине жице. Пошто су анализирани подаци показали да је процес изузетно стабилан, ова одлука је донета због недостатка података за обучавање алгоритма.



Слика 4.1.2-3 Микроскопски приказ попречног пресека залемљеног споја (израдио аутор)

На истој испитиваној јединици се врши додатни тест ради уштеде трошкова индукваних разарањем дела - тест кидања. Различити контакт је монтиран на контролник за кидање ради одређивања силе разарања. Резултати теста се ручно уносе у Excel табелу и чувају као PDF на SharePoint-у.

Модел предвиђања машинског учења могу се применити за предвиђање исхода одређених производних процеса. Уколико се моделу машинског учења предају подаци из производног процеса (параметри процеса као што су притисак, температура, напон...) и резултати деструктивних тестова (димензије пресека жице, присуство дефекта, сила кидања итд.), могу се применити различити алгоритми за формирање предвиђања за будућу производњу (Badora et al., 2021). Када један модел машинског учења буде оптимизован за одређени процес и завршено обучавање модела са историјским подацима (подаци о процесу и резултати деструктивних тестова), успешно може бити примењен за надгледање производног процеса нових делова и предвиђање хипотетичког исхода деструктивног теста без уништавања дела (Kumar et al., 2022). Добро обучен модел машинског учења може предвидети не само класу (ОК-Усаглашен или NOK-Неусаглашен), већ и конкретну вредност резултата теста, као што су ширина и висина жице, присуство дефекта итд. (Buongiorno et al., 2022). Овај приступ може се користити за смањење учесталости или, ако је могуће, потпуну замену деструктивних тестова. Уколико је деструктивно тестирање на неки начин неопходно, модел машинског учења може помоћи при одабиру делова који су највероватније неусаглашени (NOK). Предности ове методе у односу на деструктивно тестирање су бројне. Модел машинског учења може се користити за контролу 100% произведених делова, представља једнократну инвестицију, бржи је, смањује ризик по здравље и безбедност радника (у поређењу са конвенционалим деструктивним методама), решење се може применити на различитим производним локацијама са ниским или никаквим додатним трошковима...

Замена деструктивног тестирања залемљених контаката моделом машинског учења доводи до уштеде времена и новца, побољшава разумевање производа и процеса, и много више.

4.1.3 Садржај студија случаја и недостаци литературе

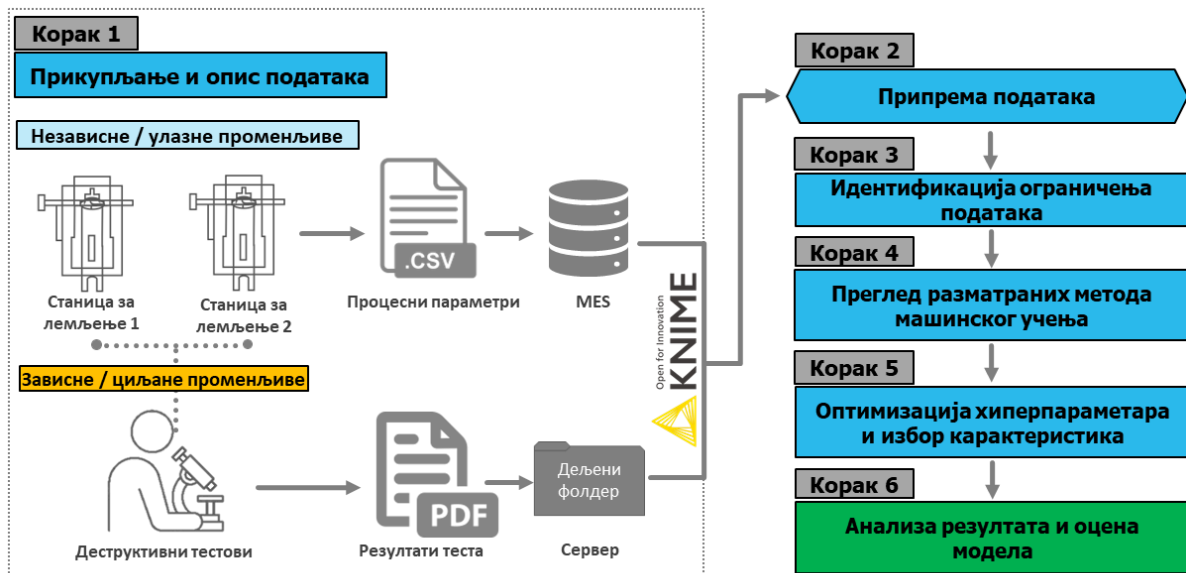
Ова студија фокусирана је на развој предикционог модела машинског учења који треба да предвиди исход деструктивног теста користећи искључиво параметре процеса лемљења, без уништавања дела. У раду се објашњавају процеси контроле квалитета, с фокусом на СКП у облику деструктивних и недеструктивних метода тестирања. Кратко је објашњен процес лемљења и деструктивни тест који је у питању. Главни део овог истраживања састоји се од прикупљања података, припреме и обраде података, избора метода машинског учења, корелационе анализе, избора карактеристика, обуке модела, оптимизације хипер параметара и евалуације модела.

Ограничен број литературних извора на теме као што су ИБР залемљених контаката, машинско учење у предвиђања резултата процеса лемљења и машинско учење предикционих модела за мале скупове података послужио је као мотивација за ово истраживање. Доступно истраживање је већином усмерено на ласерско заваривање и предикционе моделе машинског учења са значајно већим бројем неусаглашених резултата тестова (Breitenbach et al., 2021; Faragó et al., 2022; Hong et al., 2022; Rong et al., 2016; Shevchik et al., 2020; Zhou et al., 2020). Ласерско заваривање се најчешће анализира помоћу оптичке слике, што је потпуно другачији приступ од машинског учења који је заснован на визуелној улазној информацији и препознавању слика (Shevchik et al., 2019). Ова студија се фокусира на мали скуп података о параметрима процеса (напон, отпор, температура итд.) са изузетно ниским бројем неусаглашених резултата теста. Велики и мали скупови података захтевају потпуно различите алгоритме машинског учења, а низак број неусаглашених резултата тестова отежава процес обучавања модела (Badora et al., 2021; Ji et al., 2022; Zhang and Ling, 2018). Ово се такође може сматрати пропустом у литератури, пошто је већина истраживачких радова усмерена на примене машинског учења на великим скуповима података где скупови података могу имати однос 50-50% између усаглашених и неусаглашених резултата тестова (Kokol et al., 2022). При коришћењу малих скупова података у предикционим моделима машинског учења, знатно је теже обучити модел и достићи задовољавајући ниво прецизности и тачности модела у поређењу са великим скуповима података (Kokol et al., 2022). Најчешће, мали скупови података са ниским бројем неусаглашених вредности су изазовнији у поређењу са анализом великих скупова података и захтевају различит приступ, различите алгоритме и процес обучавања модела (Kokol et al., 2022; Sendek et al., 2022).

4.1.4 Материјали и методе

Ово поглавље, као што је приказано на Слици 4.1.4-1, представиће следеће целине: процес прикупљања и опис података, ограничења података, припрема података и оптимизација хипер параметара и избор карактеристика, и проистиче из првог практичног примера приказаног на Слици 4-1. Најпре је извршено прикупљање података (параметри процеса и резултати тестова). У кораку припреме података, подаци су конвертовани, филтрирани, преведени и форматирани помоћу аналитичке платформе *KNIME*. Једном када су подаци припремљени, идентификована су одређена ограничења података. Након што су подаци припремљени и дефинисана сва њихова ограничења,

приступило се проналажењу одговарајућих метода машинског учења. Избор је сведен на 4 методе. Једном када је избор метода машинског учења сужен, извршен је избор карактеристика, обука модела и оптимизација хиперпараметара за сва 4 метода. На крају, резултати су анализирани, модели оцењени и упоређени.



Слика 4.1.4-1 Графички приказ процеса сакупљања и описа података; ограничења података; припрема података; и хипер параметарска оптимизација и избор карактеристика (креирано од стране аутора)

4.1.5 Прикупљање и обележавање података

Подаци који се разматрају као улаз у овој студији потичу из процеса производње статора електричних машина. Процесни параметри са две идентичне аутоматске станице за тврдо лемљење повезане са базом података система за извршење производње (MES) представљају улазне податке. Мерења попут: дистанце пута кретања леве и десне лемне сонде, просечног напона, просечне струје, трајања лемљења, температуре леве и десне сонде и статуса лемљења се бележе за свих 24 бакарних намотаја који чине статор. Сила притиска сонде није мерљива у реалном времену, већ је унапред одређена вредност. Када би ова информација била доступна, резултати предвиђања могли би бити много прецизнији. Ако било које од мерења идентификује резултат изван граница спецификације, произведени делови добијају статус «неусаглашен» и не разматрају се за даље деструктивно тестирање за време редовне серијске производње. Укратко, улазни скуп података састоји се од података о мерењима процесних параметара за 134.535 производа са јединственим серијским бројевима са статусом «усаглашен» и 2.765 производа са статусом «неусаглашен». Циљни подаци се добијају из резултата тестирања који бележе деструктивну макро анализу и мерења силе при тесту киданја. Сваки извештај тестирања садржи следеће резултате тестова:

- Висина лемљења у микрометрима на 12 локација на статору (два намотаја на дугим, средњим и кратким растојањима од фазног прстена) за обе стране (лева и десна).
- Ширина лемљења у микрометрима на 12 локација на статору (два намотаја на дугим, средњим и кратким растојањима од фазног прстена) за обе стране (лева и десна).

- Резултати теста кидања у јединицама мере за силу [N] на 6 локација.
- Постојање пукотина на жицима које нису испуњене лемом на 6 локација.
- Утиснутост жице (мери се само ако је присутан) на 6 локација.

Укупно, циљни скуп података састоји се од 688 извештаја испитивања са статусом «усаглашен» и 10 извештаја са статусом «неусаглашен» у периоду од 32 месеца. Прикупљање података одговара кораку 1 приказаном на Слици 4.1.4 1.

4.1.5.1 Припрема података

Припрема података, обука модела и евалуација су обављени у *KNIME* аналитичкој платформи (Berthold et al., 2020, 2008). Извештаји деструктивног тестирања морају бити конвертовани из PDF-а у *Excel* формат коришћењем програма за уређивање PDF-а ради машинског читања (аутоматског ишчитавања податак директно из датотеке помоћу апликације) пре него што су учитани у *KNIME* програм, док су улазни подаци директно доступни из *KNIME*-а преко конекције са производном базом података. Ово такође одговара кораку 2 приказаном на Слици 4.1.4-1. Кораци чишћења података укључивали су уклањање колона са више од 10% недостајућих података као и колона са ниском варијансом. Након спајања у јединствени идентификатор дела (серијски број), резултујући скуп података састојао се од 585 редова, 168 нумеричких улазних карактеристика (параметри лемљења), 30 нумеричких и 15 категоричких циљних карактеристика (резултати тестова). С обзиром да се 15 категоричких карактеристика могу категоризовати само као ОК и NOK статус, а у више од 99% тестова све тестиране карактеристике су биле ОК, оне су искључене из даљег модела предикције. Из овог комбинованог скупа података, урађена је подела на скупове података за тренинг и тест у односу 70:30 користећи стратификовано узорковање на основу броја улазне станице за лемљење.

4.1.5.2 Ограничења података

С обзиром на то да су макро анализа и тестови кидања деструктивне методе тестирања, циљни скуп података је мањи у поређењу са улазним скупом података и тиме се ограничава опсег могућих алгоритама машинског учења који се могу користити, како не би дошло до преприлагођавања модела. Циљни скуп података такође је веома неуравнотежен, при чему само 1,4% делова неусаглашено. Из тог разлога, одлучено је да се задаци машинског учења формулишу не као класификација за предвиђање коначног исхода деструктивног теста, већ као регресија која има за циљ појединачна мерења, која се затим могу тумачити у вези са постојећим границама спецификација.

Што се тиче резултата тестова кидања, документовано је само да ли је део био ОК (усаглашен део) или NOK (неусаглашен део). Резултати теста не садрже информације о сили коју је део издржао, нити која је сила била довољна да га откине. Доступне информације уче алгоритам само да ли одређени процесни параметри доводе до ОК или NOK исхода при тесту кидања. Осим тога, ручна природа уноса резултата у протокол за тестирање отежала је процес уношења података: формат PDF датотеке захтевао је додатне кораке трансформације како би протоколи постали читљиви за машине; нестандартизовани формат значио је да су неки подаци попуњавани на различите начине, а различити језици (улазни подаци: немачки, циљни подаци: српски) и азбука захтевали су додатне кораке превода. Конверзија PDF датотека одговара кораку 3 приказаном на Слици 4.1.4-1.

Процес уноса података такође је довео до значајних изазова у вези са валидношћу података: садржај две колоне био је замењен за одређене тест протоколе, неки уноси су имали недостајуће цифре (нпр. «163» уместо «1163») и грешке при уносу у примарни образац (серијски број) довеле су до записа који се нису могли упарити са улазним подацима. То је довело до додатних ручних напора за чишћење података.

4.1.6 Преглед разматраних метода машинског учења

Постоји веома мало истраживачких чланака који се фокусирају на примену машинског учења у процесима лемљења уопште, а још мање или нимало оних који се посебно фокусирају на тврдо лемљење. Имајући у виду да су се модели машинског учења примењени на сличне процесе (нпр. Ласерско заваривање) показали као ефикасна и ефективна метода верификације процеса, извршен је преглед различитих метода машинског учења како би се пронашле одговарајуће методе (Faragó et al., 2022; Rong et al., 2016; Shevchik et al., 2020).

С обзиром на то да су како улазни подаци (параметри процеса) тако и излазни подаци (резултати деструктивног тестирања) доступни у сценарију који је приказан, надгледани алгоритми учења су одабрани као метода за даље истраживање. Преглед метода машинског учења одговара кораку 4 приказаном на Слици 4.1.4-1. Надгледано учење укључује податке који су процењени, а затим измењени додатним информацијама како би се пратили алгоритми машинског учења. У суштини, само је питање пружања података у довољним количинама, који су већ сачувани са одговарајућом вредношћу функције. У таквом случају, говори се о «обележеним подацима» (Frochte, 2021). Надаље, надгледано учење је подељено на два сегмента – класификацију и регресију. У класификацији, предефинисане категорије или класе се додељују сваком елементу (Јо, 2021). То значи да су излазне вредности циљне класе дискретне у класификационим проблемима. Регресија процењује излазну вредност на основу више улазних фактора (Јо, 2021). У регресивним проблемима, излаз је континуиран. Будући да је доступни обележени скуп података мали, избор најбоље методе машинског учења за мале скупове података се сматра додатним критеријумом за одабир. Истовремено, треба размотрити разне замке у скуповима података. У основи, тренинг подаци су комбинација две компоненте: сигнал + шум.

Ако се сигнална компонента сматра главном информацијом у подацима, а шумна компонента недефинисаном, са високо променљивим подацима, концепти преприлагођености (енг. *overfitting*) и подприлагођености (енг. *underfitting*) могу се лако разумети (Јiang, 2021). У случају када је модел превише једноставан да би ухватио све услове сигнала, обучени модел ће давати лоше резултате. Овај случај се назива подприлагођеност (Јiang, 2021). С друге стране, сложени модел ће покушати да ухвати све шумове у датим подацима и апстрахује модел од свих регуларности сигнала. Коришћење сложеног модела може значајно утицати на обуку резултата због присуства шумне компоненте (Јiang, 2021). Према критеријумима пројекта и доступности података, разматране су и изабране различите методе које су описане у поглављу 3, а то су:

- Линерна регресија
- *Random Forest*
- *Gradient Boosted Trees*
- *Kernel Ridge Regression*

Сви одабрани алгоритми имају доказану примену у обучавању модела на малим скуповима података у мањој или већој мери. Упоредном анализом ће се извршити одабир најбољег модела за конкретни пројекти задатак ове студије случаја.

4.1.7 Оптимизација хипер параметара и одабир карактеристика

Са величином тренинг скупа од само 409 редова и 168 улазних карактеристика, постоји повећани ризик да алгоритам машинског учења пронађе шаблоне који нису важећи за општу популацију (Jensen and Shen, 2008). Зато је уведена петља напредне селекције карактеристика како би се претходно одабрао скуп улазних карактеристика за тренирање модела линеарне регресије; ово одговара кораку 5 приказаном на Слици 4.1.4-1. За сваку циљну променљиву, број карактеристика је оптимизован максимизирањем метрике оцене «Прилагођени R^2 », која кажњава додавање несродних улазних променљивих у модел; ово одговара кораку 5 приказаном на Слици 4.1.4-1 (Devore, 2012).

Табела 4.1.7-1. приказује преглед техника оптимизације хипер параметара које су примењене за сваки алгоритам машинског учења. Ове методе су имплементиране користећи *KNIME* програм за оптимизацију параметара у вези са двоструком крос-валидацијом.

Табела 4.1.7-1. Преглед поставки хипер параметара оптимизације

Модел	Метода оптимизације	Параметар модела	Параметри оптимизације
Random Forest Regression	Grid Search	nr_models	Start: 50 Stop: 200 Step size: 10
Random Forest Regression	Grid Search	max_depth	Start: 1 Stop: 31 Step size: 2
Gradient Boosted Tree Regression	Grid Search	max_depth	Start: 2 Stop: 10 Step size: 2
Gradient Boosted Tree Regression	Grid Search	learning_rate	Start: 0.1 Stop: 1.0 Step size: 0.1
Kernel Ridge Regression (Linear Kernel)	Grid Search	alpha	Start: 0.1 Stop: 1.0 Step size: 0.1
Kernel Ridge Regression (RBF Kernel)	Bayesian Optimization (TPE)	alpha	Start: 0.1 Stop: 1.0 Max_iterations: 100 Warm up: 40 Gamma: 0.25 No_candidates: 25
Kernel Ridge Regression (RBF Kernel)	Bayesian Optimization (TPE)	gamma	Start: 0.00005 Stop: 0.1 Max_iterations: 100 Warm up: 40 Gamma: 0.25 No_candidates: 25

За оптимизацију хипер параметара модела и општу оцену модела, коришћен је коефицијент детерминације R^2 . Овај коефицијент израчунава пропорцију варијансе у циљној променљивој која се може предвидети из улазних променљивих и имплементиран је у облику *KNIME „Numeric Scorer“* чвора (Berthold et al., 2008).


4.1.8 Резултати примене модела машинског учења и дискусија

У овом одељку биће приказана корелациона анализа заједно са резултатима регресионог модела. Такође, присутна је и дискусија о општим предностима овог приступа.

4.1.8.1 Корелациона анализа


Извршена је корелациона анализа како би се измерила снага линеарне везе између параметара процеса и мерења деструктивног теста. Ово одговара кораку 3 приказаном на Слици 4.1.4-1. Резултирало је са неколико јаких корелација између параметара лемљења „Пут кретања лемне сонде“ и мерења из макро анализе „висина жице после лемљења“ и „жице после лемљења“ за исте намотаје на статору. Ова открића потврђују производну логику изложену у првом сегменту овог поглавља.

Утврђено је да, генерално, неусаглашени резултати макро анализе нису видљиви, изоловани, подаци када се разматрају мерења макро анализе, већ их можемо наћи у центру расподеле, као што приказује Слика 4.1.8.1-1. Додатно, на Слици 4.1.8.1-1 може се видети да се ширина залемљеног споја повећава када се пут кретања лемне сонде повећава.



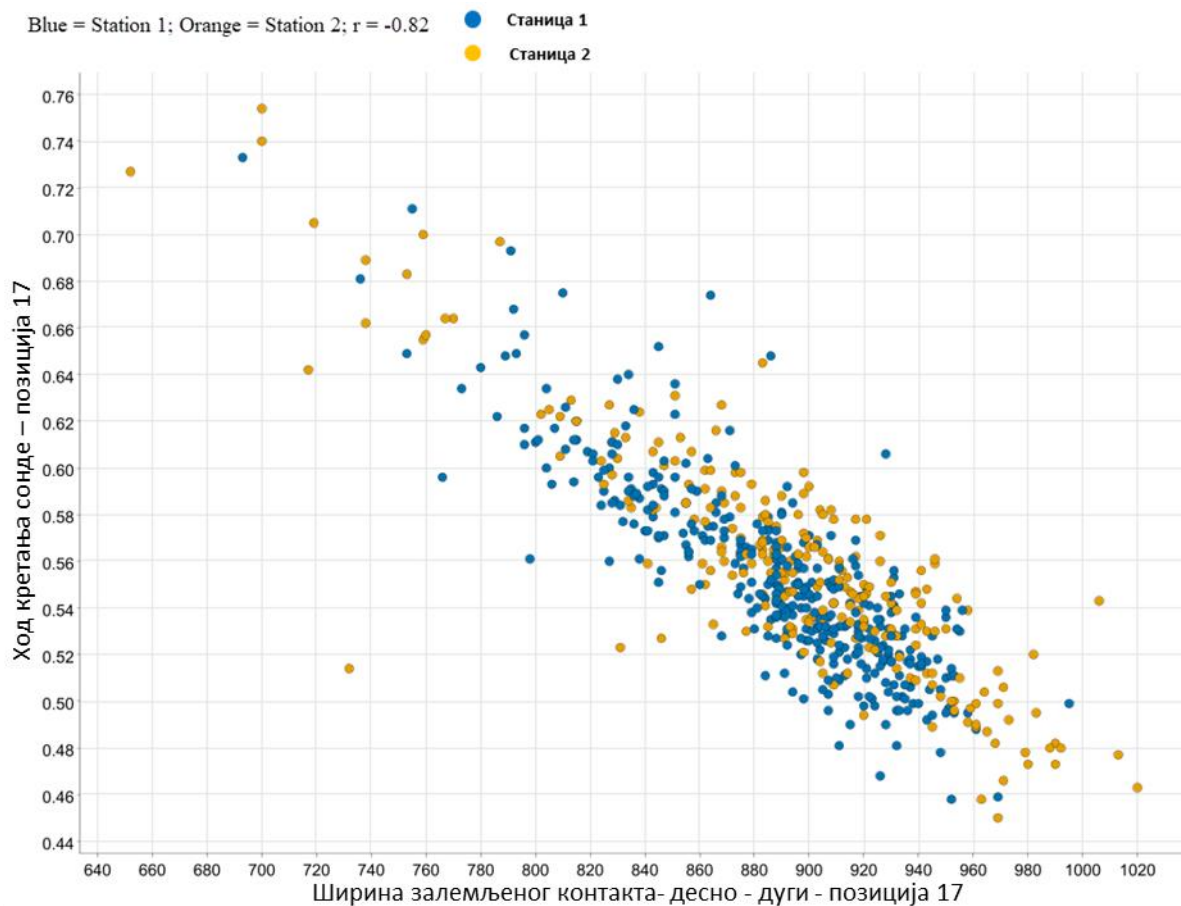
Слика 4.1.8.1-1 Дијаграм простирања корелације између залемљених параметара и макро аналитичких мерења. Црвено = неуспешна анализа, зелено = успешна анализа. $R = 0.72$

Слика 4.1.8.1-2 приказује исту појаву за неусаглашене резултате испитивања силе кидања. Додатно, на Слици 4.1.8.1-2 можемо видети да се са повећањем пута кретања лемне сонде смањује висина залемљеног споја.



Слика 4.1.8.1-2 Распрострањеност корелације између параметара лемљења и макро анализе. Црвена боја представља неуспешно испитивања силе кидања, зелена боја представља успешно испитивање силе кидања. $R = -0,75$

Слика 4.1.8.1-3 приказује разлике између две станице за лемљење. Разлика у расподели је била присутна код скоро свих мерења и довела је до одлуке да се користи стратификовано узорковање при подели тренинг и тест скупа за обуку модела.



Слика 4.1.8.1-3 Распрострањеност корелације између параметара лемљења и макро анализе. Плава боја представља лемљење станице 1, наранџаста боја представља лемљење станице 2. $R = -0,82$

На Слици 4.1.8.1-3 је видљиво да нема значајних разлика између две станице, тако да нису потребни додатни кораци.

4.1.8.2 Резултати регресионог модела

Укупно, за 19 од 30 нумеричких циљних променљивих постигнуте су перформансе модела са R^2 вредношћу 0.5 или више. Од тих 19, Линеарна регресија се показала најбоље за 11, *Linear Kernel Ridge* регресија за 4, *Gradient Boosted Trees* регресија за 3, а *Random Forest* регресија за 1. Поређење резултата свих модела према циљној вредности може се видети у Табели 2.

Из Табеле 4.1.8.2-1 се види значајна разлика између перформанси предвиђања макро анализе и резултата теста кидања. Ниједан од модела није био у стању да прецизно предвиди силу под којом ће се проводник прекинути при кидању. Такође је занимљиво да *Kernel Ridge* регресија никада није била најбољи модел, ни у једном случају са R^2 вредношћу већом од 0.5. Овај сегмент одговара кораку 6 приказаном у Слици 4-1 (оцена модела).

Табела 4.1.8.2-1 Резултати оцене модела: Gradient Boosted Trees (GB), Kernel Ridge регресија (KRR), Линеарна регресија (LR), Random Forest (RF), Kernel Ridge Regression with Radial Basis Function (KRR_RBF)

Циљни подаци	GB	KRR	LR	RF	KRR RBF	Max	Најбољи модел
	R ²	R ²	R ²	R ²	R ²	R ²	
средњи_лем9_лево+висина жице након лемљења [μm]	0.723	0.692	0.815	0.703	0.078	0.815	LR
дуги_лем7_десно+висина жице након лемљења [μm]	0.789	0.722	0.792	0.652	0.401	0.792	LR
дуги_лем5_десно+висина жице након лемљења [μm]	0.747	0.696	0.761	0.604	0.075	0.761	LR
дуги_лем7_лево+висина жице након лемљења [μm]	0.675	0.669	0.698	0.732	0.379	0.732	RF
кратки_лем8_лево+висина жице након лемљења [μm]	0.571	0.605	0.713	0.665	0.055	0.713	LR
кратки_лем8_десно+висина жице након лемљења [μm]	0.519	0.327	0.668	0.242	0.317	0.668	LR
дуги_лем5_лево+висина жице након лемљења [μm]	0.618	0.524	0.668	0.575	0.085	0.668	LR
дуги_лем7_десно+ширина лема [μm]	0.664	0.575	0.594	0.526	0.174	0.664	GB
средњи_лем9_лево+ширина лема [μm]	0.639	0.644	0.659	0.328	0.574	0.659	LR
дуги_лем5_десно+ширина лема [μm]	0.629	0.605	0.655	0.585	0.513	0.655	LR
дуги_лем7_лево+ширина лема [μm]	0.626	0.645	0.506	0.322	0.459	0.645	KRR
средњи_лем7_десно+висина жице након лемљења [μm]	0.635	0.645	0.637	0.639	0.131	0.645	KRR
средњи_лем9_десно+висина жице након лемљења [μm]	0.615	0.591	0.641	0.616	0.243	0.641	LR
дуги_лем5_лево+ширина лема [μm]	0.622	0.567	0.542	0.538	0.315	0.622	GB
кратки_лем6_лево+висина жице након лемљења [μm]	0.569	0.416	0.611	0.6	-0.002	0.611	LR
кратки_лем8_лево+ширина лема [μm]	0.33	0.609	0.604	0.572	0.442	0.609	KRR
средњи_лем7_лево+висина жице након лемљења [μm]	0.574	0.489	0.607	0.568	0.261	0.607	LR
кратки_лем6_лево+ширина лема [μm]	0.568	0.5	0.434	0.237	0.026	0.568	GB
средњи_лем7_лево+ширина лема [μm]	0.532	0.559	0.469	0.303	0.472	0.559	KRR

кратки_лем6_десно+висина жице након лемљења [μm]	0.439	0.454	0.486	0.431	0.138	0.486	LR
средњи_лем7_десно+ширина лема [μm]	0.455	0.446	0.423	0.481	0.371	0.481	RF

На Слици 4.1.8.2-1 приказани су графикони предвиђених и стварних вредности висине проводника за циљну променљиву са највишим R^2 (0.815), у овом случају предвиђених помоћу методе линеарне регресије. Иако је анализиран мали скуп података и подаци о процесним параметрима били су ограничени и недостајали су јако битни подаци (као што је сила притискања лемне сонде), то је било довољно да се ефикасно предвиди димензија попречног пресека контакта. Обзиром да техничар у соби за сечење увек сече исте контакте за стандардни деструктивни тест (контакти: 9, 10, 11, 21, 22 и 23), а остале контакте само по посебној потреби, постојало је много више података за те контакте него за све друге. Ова чињеница није имала велики утицај на резултате предвиђања за све појединачне контакте.




Слика 4.1.8.2-1 Графикони предвиђених и стварних вредности висине проводника за циљну променљиву са највишим R^2 (0.815)

На Слици 4.1.8.2-2 се може видети да, чак и за модел циљног макро анализаног параметра са најлошијим резултатима, предвиђене вредности нису ни близу граничне вредности спецификације. На Слици 4.1.8.2-2 се види да је процес стабилан и знатно изнад доње границе спецификације од 700 μm (зелена линија). Са практичног аспекта, иако предвиђања нису тако прецизна, било би безбедно за овај конкретни процес користити предиктивни модел машинског учења као метод за контролу процеса.



Слика 4.1.8.2-2 Графициони предвиђених и стварних вредности ширине проводника за циљни макро аналитички параметар са најслабијим R^2 (0.426)

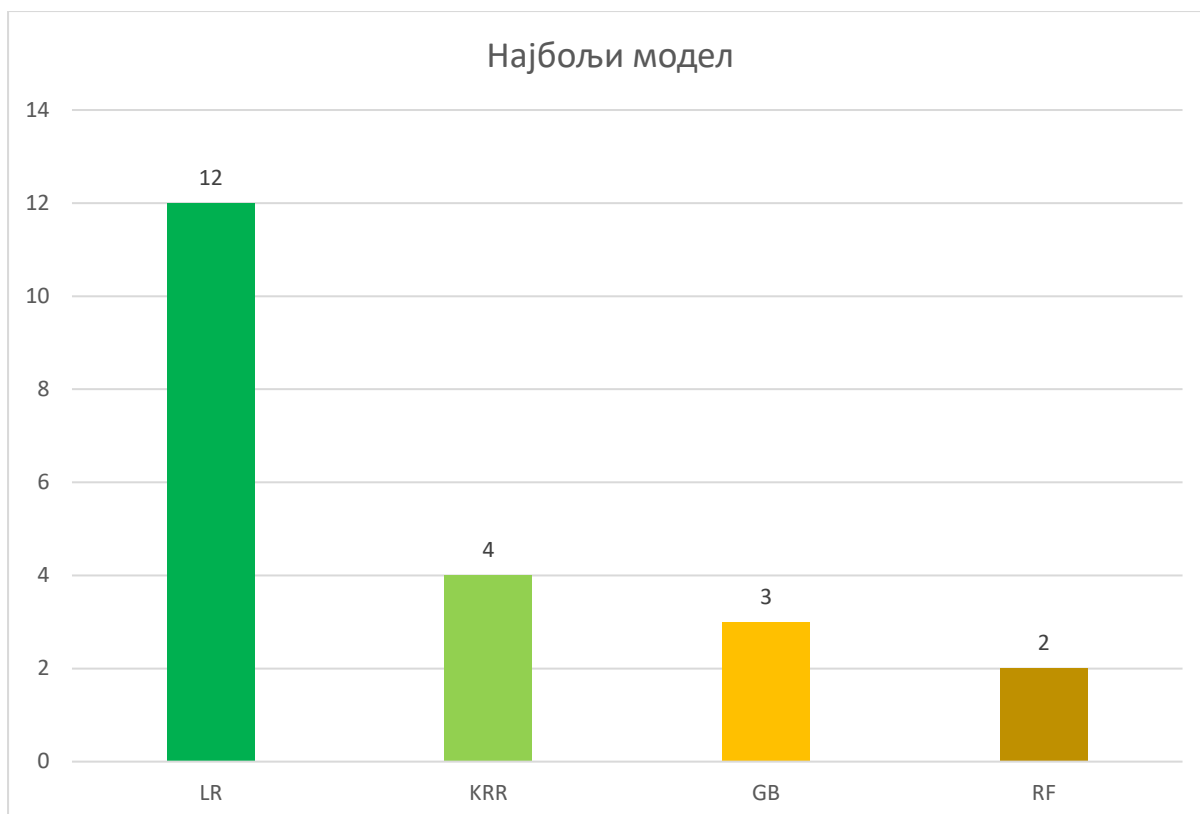
Слици 4.1.8.2-3 приказује графикон предвиђених вредности у односу на стварне вредности највишег резултата испитивања силе кидања (R^2 0.296). Подаци о испитивању силе кидања били су врло ограничени. Само испитивање силе кидања садржи податак о сили на којој је жица пукла или коју је силу издржала и остала целовита. Ипак, то није било документовано у резултатима испитивања. Једина информација доступна у резултатима испитивања силе кидања је да ли је резултат испитивања у реду или не (ОК или NOK).



Слика 4.1.8.2-3 Графикон предвиђених и стварних вредности највишег резултата испитивања силе кидања (R^2 0.296)

Пошто недостаје ова нумеричка вредност, било је веома тешко предвидети резултат испитивања силе кидања у нумеричком облику. Пошто је процес стабилан, није било многих варијација и све предвиђене вредности су се налазиле у опсегу усаглашености (опсег делова који су усаглашени). Зато се може закључити да, иако предвиђања испитивања силе кидања нису прецизна, резултати макро анализе се могу прецизно предвидети помоћу модела машинског учења.

На Слици 4.1.8.2-4 приказан је број инстанци по моделима колико су пута произвели најбоље превиђање за дату вредност.



Слика 4.1.8.2-4 – Приказ инстанци у којима је одређени модел предвидео најбоље резултате (LR – Linear Regression, KRR – Kernel Ridge Regression, GB – Gradient Boosted Trees, RF – Random Forest)

Сваки од модела је радио предвиђање, регресију, на основу улазних вредности (различитих позиција лемног споја) које су касније проверене са стварним резултатима излазних вредности (резултатима деструктивних тестова), за укупно 21 инстанцу су произведени резултати прихватљиве прецизности. За сваку позицију један од алгоритама је био најпрецизнији, односно предвидео вредност најближу истинитој. На Слици 4.1.8.2-4 може се видети да је линеарна регресија била најпоузданији модел за дати задатак у највећем броју случајева.

4.1.9 Предности приступа предвиђања квалитета помоћу машинског учења

Општа идеја била је обучити модел да предвиди ширину и висину жице, присуство пукотина и пора, и силу кидања потребну за откидање контакта како би се унапредио процес контроле квалитета. Уколико би сва ова предвиђања помоћу машинског учења била могућа, деструктивна испитивања би могла бити прекинута или минимизирана. То би довело до значајне уштеде у времену, трошковима испитивања и смањењу ризика за здравље и безбедност запослених; омогућило би испитивање 100% производа на производној линији и сачувао би се контролисани производ. У тренутном сценарију деструктивних испитивања, статор треба произвести, донети у лабораторију, документовати поступак, затим сећи, брусити, полирати и посматрати под микроскопом; мора се направити извештај, а узорак треба отписати као уништен. С друге стране, модел предвиђања помоћу машинског учења би био интегрисан у предикативни производну линију без потребе за додатним активностима за испитивање дела које не доприносе

вредности производа. Сви резултати би били смештени у информатички систем фабрике.

У складу са одређеним ограничењима пројекта и подацима, модел предвиђања помоћу машинског учења није у потпуности способан да замени деструктивна испитивања. Резултати испитивања силе кидања нису могли бити прецизно предвиђени пошто подаци (резултати тестова) садрже само информацију да ли је узорак прошао деструктивно испитивање или не, али не и стварну вредност силе кидања. Циљ је био предвидети нумеричку вредност, а не класу (ОК или НОК). Пукотине и празнине нису могле бити предвиђене јер је у бази података био представљен изузетно мали број тих дефекта. Ширина и висина жице при припајању контакта били су задовољавајуће прецизно предвиђени.

На основу резултата добијених током експеримента, могуће је ипак направити одређена побољшања у систему контроле квалитета. Пошто статистичко испитивање контролише само мали део целе производње, боље је испитивати најлошији могући део него било који насумични део. Са ограниченим могућностима предвиђања, алгоритам машинског учења може се користити за избор/препоруку критичних делова који треба да буду подвргнути деструктивном испитивању. Ово има две користи. Прво, ако алгоритам машинског учења предвиђа сумњиве делове, много је јефтиније и временски ефикасније тестирање у фабрици него слање истих купцу и добијање рекламације. Управљање рекламацијом може укључивати активности сортирања у иностранству, повлачење делова, казне за заустављање производне линије код купца, смањења оцене добављача и свакако много времена локалног инжењерског тима који се бави рекламацијом. Друго, ако се најлошији део преда деструктивном испитивању, може се сазнати да ли је потребно оптимизовати параметре производног процеса. Додатно, када се комплетан електрични мотор склопи и испитује на EOL (крај линије) могу се открити дефекти процеса припајања. То значи да постоји могућност да се у лабораторији уништи добар део за тестирање, а затим отпише и други на EOL-у.

Иако су могућности ограничене, овај модел предвиђања може бити користан у производњи. Са прикупљањем више података током времена, алгоритам ће бити поново обучен и може постићи већу ефикасност. Решење се лако може пренети на више локација у свету са сличним производним процесима без претераног инвестирања, осим процеса прикупљања и обраде података на свакој конкретној локацији. Друге деструктивне и методе ИБР захтевале би релативно високу инвестицију у опреми за испитивање. Током времена, могу се појавити боље методе машинског учења које ће пружити боље резултате него оне који су добијени у овом експерименту. Изузетно је важно да се постави правац за будући развој. Имајући у виду да вештачка интелигенција и машинско учење могу бити веома корисни ако им се пруже тачни и квалитетни подаци, неопходно је планирати и пројектовати производне процесе за будућност и будуће интеграције паметних решења. Процеси производње и резултати испитивања морају бити пројектовани тако да пруже праву врсту података машинском учењу у блиској будућности.

4.1.10 Разматрања студије случаја

У производњи релативно скупог производа, деструктивна испитивања могу представљати велике финансијске губитке. Недеструктивне методе испитивања пружају решење за овај проблем смањујући трошкове испитивања. Ипак, нису све методе примењиве у сваком пројекту. У овом конкретном случају, циљ је био развити ИБР са 100% фреквенцијом тестирања у производним условима, кратким периодом поврата

инвестиције и високом преносивошћу на друге пројекте и локације. Неке методе испитивања захтевају значајне финансијске инвестиције, као што је компјутерска томографија, док неки нису погодни за тестирање у производњи усмереној на брзину, као што је ултразвучно испитивање. Постоји и ризик од контаминације производа при примени неких метода, као што су испитивање помоћу магнетних честица или пенетрантно испитивање, док неке методе захтевају пуно времена за имплементацију и реконструкцију станица у производњи, као што је испитивање помоћу вртложних струја. Има и метода које не пружају неопходну резолуцију мерења за дату примену. У овом случају, модел предвиђања помоћу машинског учења пронађен је као најбоље решење за захтеве пројекта.

Доказано је кроз резултате предвиђања исхода да је могуће предвидети ширину и висину контакта при лемљењу, који су обично у вези са улазним параметрима. Макро анализа може бити замењена алгоритмом машинског учења за предвиђање, узимајући у обзир удаљеност од граница спецификација (Рајић et al., 2023a). Међутим, сила кидања није могла бити прецизно предвиђена због недостатка информација о процесу и резултатима деструктивног испитивања. Сила притиска сонде при лемљењу је критична информација за овај процес и у скупу обрађених података представља фиксну задату вредност која се не мери у реалном времену. Резултати деструктивних испитивања не садрже информације о вредности силе кидања, већ само да ли је испитивање у реду или не.

Коришћена су четири различита модела машинског учења за предвиђања на малим скуповима података како би се предвидели исходи процеса лемљења и резултати испитивања. Методе које су коришћене у овој студији случаја били су линеарна регресија, линеарна Kernel Ridge регресија, Gradient Boosted Trees регресије и Random Forest регресије. Од 30 тестираних нумеричких вредности, 19 је имало R^2 вредност од 0,5 или већу. Од тих 19, најбоље резултате је постигла линеарна регресија за 11, линеарна Kernel Ridge регресија за 4, Gradient Boosted Trees регресија за 3 и Random Forest регресије за 1. На основу евалуације, линеарна регресија је имала најбоље резултате са датим скупом података.

Да би се постигли задовољавајући резултати, улазни подаци морају бити доступни у довољном обиму (што значи да морају садржати параметре који дефинишу процес и имати довољно ОК и НОК вредности), високог квалитета, као и добро форматирани. Дати скуп података садржао је 98% усаглашених резултата испитивања и мање од 2% неусаглашених резултата. Ова пропорција је веома ограничавајућа и представљала је велики изазов. Бољи однос података вероватно би довео до веће тачности предвиђања, што је остављено као тема за будућа истраживања. Уколико неке мерене вредности које дефинишу процес недостају у скупу података за тренинг модела (као што је сила притиска сонде у овом случају), то такође смањује успешност модела предвиђања. Истих ограничења има и у вези са недостајањем вредности из извештаја о испитивању (као што је вредност силе кидања). Мали скупови података су ограничени, али могу довести до успешног модела предвиђања, међутим недостатак података/вредности који дефинишу процес или испитивање значајно утиче на успешност предвиђања.

Ограничена литература доступна о темама као што су ИБР залемљених контаката, машинско учење за предвиђање исхода процеса лемљења и машинско учење за предвиђање на малим скуповима података служила је као мотив за ово истраживање. Међутим, већина доступних истраживања је усмерена на ласерско заваривање и моделе машинског учења за предвиђања на великим скуповима података, са значајном количином неусаглашених резултата. Иако се ласерско заваривање често анализира помоћу оптичког сигнала, што се заснива на визуелном уносу и препознавању слика,

алгоритми машинског учења за велике и мале скупове података који се базирају на стрингу/низу текстуалних података захтевају различите приступе. Поред тога, мали број неусаглашених резултата у малим скуповима података значајно отежава тренирање модела. Овај недостатак у литератури отвара простор за више истраживања примена машинског учења на малим скуповима података са малим бројем неусаглашених вредности, што захтева различите алгоритме и процесе тренирања модела у односу на аналитику великих скупова података. Укратко, такви скупови података су изазовнији за рад и захтевају потпуно другачији приступ.

Будућа истраживања могу се гранати у више праваца. Пре свега, треба истражити моделе машинског учења за предвиђање на малим скуповима података. Различити индустријски процеси могли би имати користи од модела предвиђања машинског учења, али су ограничени малим скуповима података. Развој нових алгоритама или унапређење постојећих могло би бити корисно. Различите недеструктивне технике за предвиђање исхода процеса лемљења контаката (или заваривања уопште) могле би се унапредити алгоритмима машинског учења, на пример у интерпретацији резултата тестирања ради боље ефикасности и ефективности тестирања. Једна од стратешких ставки за будућа истраживања би била пројектовање производа, процеса производње и тестирања који омогућавају лаку интеграцију модела предвиђања заснованих на машинском учењу. Важно је имати на уму који подаци ће бити потребни за новопроектване производе/процесе/тестове за годину или две, када ће већ постојати довољно података за обуку модела машинског учења.

4.2 Примена машинског вида за класификацију и детекцију дефеката при наливању лепка за процесе спајања у аутомобилској индустрији

Прецизно и ефикасно откривање неусаглашености и дефеката од суштинског је значаја, посебно када се ради о спајању елемената лепком. При наливању лепка на одређени део, могуће су појаве различитих дефеката као што су мехури, недовољно наливан лепак или контаминације лепка и лепљене површине, што може утицати на квалитет и трајност производа.

С тим у виду, развој и примена напредних технологија заснованих на методама вештачке интелигенције представљају промишљен приступ у области контроле квалитета у аутомобилској индустрији. У овом поглављу, фокус ће бити на развоју модела за детекцију дефеката при наливању лепка помоћу алгоритама за препознавање слика.

Пројекат има за циљ да изгради двостепени модел који обухвата класификацију слика у првом нивоу и детекцију објеката у другом нивоу. Први ниво модела класификује слике у две категорије – са дефектима (NOK) и без дефеката (OK). Други ниво модела има задатак да на сликама које су проглашене као NOK локализује и препозна дефекте, тј. тачно одреди који дефекти су присутни на производу.

У овом поглављу ће бити обрађени сви кораци од сакупљања и обележавања (анотирања) скупа слика, преко претпроцесирања слика и избора најподобнијих алгоритама, па све до имплементације и тестирања модела. Описаће се изазови са којима се имплементатори оваквог решења могу сусрести и неколико начина за њихово превазилажење. Такође, биће приказане метрике за ефикасност и перформансе креираног модела на реалним подацима.

Примена оваквог модела има потенцијал да значајно унапреди процес контроле квалитета у аутомобилској индустрији, смањујући потребу за визуелном контролом, грешку људског фактора, и побољшавајући прецизност и брзину детекције дефеката. Ово би допринело повећању производне ефикасности и смањењу ризика од неисправних производа, што је од кључног значаја у захтевној и компетитивној аутомобилској индустрији.

4.2.1 Уводна разматрања студије случаја

У овој конкретној студији случаја биће приказан процес примене вештачке интелигенције у циљу унапређења застарелог система за препознавање дефеката заснованог на детекцији пиксела. Концепт је такав да се процес контроле квалитета модернизује са минималним улагањима. Систем који се унапређује се састоји од производне линије, камере старе преко 25 година, рачунара који покреће апликацију за детекцију дефеката засновану на детекцији пиксела старог преко 20 година, који ради са оперативним системом *Windows 98*.

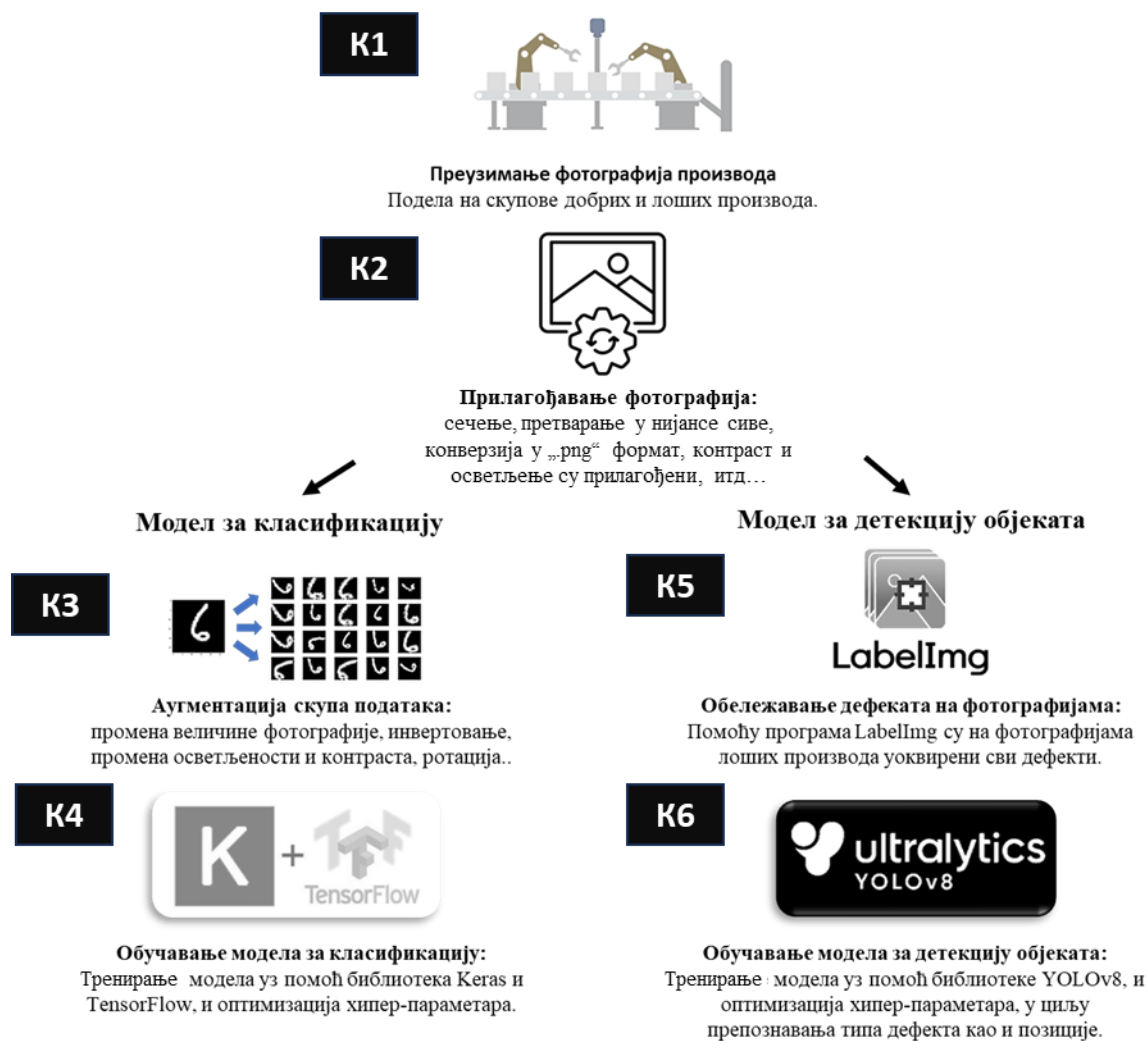
Систем контроле квалитета помоћу камере заснован на детекцији пиксела је конвенционалан приступ који се често користио у процесима контроле квалитета у производним процесима. Овај систем ради на принципу детекције одређених пиксела у слици који одговарају дефектима или неусаглашеностима. Камере снимају визуелне податке, а затим се користе алгоритми за обраду слика и детекцију дефекта на основу промене пиксела у нумеричке вредности и њиховог упоређивања у односу на унапред дефинисане параметре (Zhang et al., 2014).

Насупрот томе, решења заснована на примени вештачке интелигенције представљају новији и напреднији приступ контроли квалитета. У оваквим системима,

вештачка интелигенција, посебно методи машинског учења и дубоког учења, примењују се у анализи и обради слика. Алгоритми усмерени на препознавање образаца и карактеристика на сликама обучавају се на великом скупу аотираних података. Ово омогућава систему да аутоматски научи да детектује и класификује дефекте без потребе за унапред дефинисаним правилним параметрима.

Главна предност решења заснованих на вештачкој интелигенцији је њихова способност да самостално уче из података и адаптирају се на различите услове и окружења. Ово им даје већу робусност и тачност у детекцији дефеката, чак и у случају варијабилности осветљења и других фактора који могу утицати на снимљене слике. Истовремено, имплементација решења заснованих на вештачкој интелигенцији може бити изазовна и захтевати додатну обуку и анализу алгоритама, али предности које нуде у смислу повећања ефикасности и прецизности контроле квалитета чине их изузетно вредним инструментом у савременом окружењу производње.

Истраживање је извршено да би се пронашао одговарајући приступ примени вештачке интелигенције и закључено је да надгледано учење може пружити најбоље резултате за ову примену (Nafiz et al., 2023). Конволуцијске неуронске мреже широко се користе у сличним применама и могу бити релативно брзо имплементирани (Terziyan and Vitko, 2023). Сlike су претпроцесирани, исечене, претворене у црно беле, извезене у „.png“ формат, контраст и осветљење су прилагођени, а примењено је и прилагођавање граничних вредности пиксела помоћу Python скрипте (Hai et al., 2023). Скуп података је вештачки проширен применом различитих техника аугментације података као што су промена величине слике, инвертовање, промена осветљености и контраста, и ротација (Iglesias et al., 2023). CNN креиран за ову примену користио је библиотеке као што су Keras и TensorFlow које садрже велики број корисних алата за препознавање слика и детекцију дефекта (Gadri et al., 2022). Креирана су два нивоа решења. Први ниво је била једноставна класификација слика, утврђивање да ли је део усаглашен или неусаглашен на основу Keras и TensorFlow-а. Други ниво је детектовање типа и позиције дефекта на основу YOLOv8. Архитектура другог нивоа (YOLOv8) има укупно 52 конволуцијска слоја. „Pooling“ слојеви коришћени у конволуцијској мрежи су „Max Pooling“ слојеви са језгром 2x2 и кораком 2. Процес је шематски приказан на Слици 4.2.1-1 и односи се на други практични пројекат приказан на Слици 4-1.



Слика 4.2.1-1 Шематски приказ процес прикупљања и обрада података, и тренирања модела за класификацију и детекцију објеката (израдио аутор)


Двостепени приступ је примењен јер је модел класификације имао већу прецизност при одређивању усаглашености производа на слици (99%), док је модел за детекцију типа и позиције дефеката имао прецизност 97%. Обзиром да је у описаном пројекту од изузетне важности била прецизност модела али и информација о типу и позицији дефекта ради ефикаснијег управљања квалитетом и процесом наливања лепка.

4.2.2 Анализа проблема

У овој конкретној студији случаја дат је приказ унапређења система за детекцију дефеката на конкретном примеру. Цео процес развоја модела је приказан без специфичних информација о процесу или производу, већ као генерализовани приступ решењу проблема детекције дефеката при машинском наливању лепка помоћу вештачке интелигенције.

У овом случају је реч о производној линији која функционише са 15% шкарта на станици за наливање лепка. Две трећине делова које систем за детекцију пиксела прогласи шкартом су заправо добри делови (10% укупне производње). Циљ је смањити количину лажног шкарта, односно повећати тачност система детекције неусаглашених

делова са 90% на минимално 97%. Поменута нетачност система од 3% би свесно за циљ имала прекомерни квалитет производа, те би се на тај начин штитио крајњи купац јер би се гранични делови одстрањивали и смањили ризик за добијање рекламације. Рекламације могу бити знатно скупе и изискивати доста времена за разрешење, па је ефикасније имати благо повишене критеријуме квалитета у односу на купчеве захтеве.



Слика 4.2.2-1 Приказ застарелог система за детекцију дефеката заснованог на детекцији пиксела наспрам развијеног решења заснованог на моделу машинског учења (израдио аутор)

Решење је засновано на благој измени производне линије са минималним улагањима. Концепт је прилагођен малим и средњим предузећима која немају значајна средства која би инвестирала у застареле системе за детекцију дефеката. Уколико таква предузећа имају међу својим кадровима особље са одређеним знањем о програмирању и развоју модела машинског учења, могу са изузетно ниским улагањима остварити многоструке бенефите, како финансијске тако и не финансијске. Систем би се унапредио тако што би се стари рачунар заменио савременим рачунаром канцеларијске конфигурације, који би могао да покрене модерне *Python* моделе, а камера и остатак линијског система остао непромењен, као на Слици 4.2.2-1.

4.2.3 Скуп података

Улазне информације за овај пројекат биле су слике са индустријске камере. База података слика сакупљених за овај пројекат садржала је 1000 слика усаглашених делова и 1000 слика неусаглашених делова. Слике су преузете директно са производног рачунара, помоћу компанијске апликације за удаљени приступ. Апликација је садржала опцију да складишти слике свих производа у току дефинисаног временског интервала, само слике усаглашених производа, или само слике неусаглашених производа. Након избора жељене опције апликацију је било потребно покренути у позадини на производном рачунару. Слике неусаглашених делова су могле садржати више дефеката истог типа, или више дефеката различитог типа, или пак само један дефект. Обзиром да тренутни систем није довољно прецизан, све прикупљене слике су прошле контролу од стране три експерта за квалитет производа како би скуп усаглашених слика садржао

само усаглашене производе и обратно. Дефекти који су уочени у фази истраживања на прикупљеним сликама су:

- Лоше наливен лепак,
- Није наливен лепак,
- Преливање лепка,
- Оштећења,
- Контаминације,
- Мехури у лепку,
- Лоше позициониран производ,
- Недостаје производ у лежишту.

Слике су биле у „.bmp“ формату, резолуције 1280*1024 пиксела, у боји, са деловима које је требало исећи, односно уклонити. У одређеним случајевима су слике имале исто име па је и то требало накнадно исправити.

Главни проблеми при сакупљању података су били проблеми у конекцији са производним рачунаром, неравномерна учесталост свих типова дефеката, као и различити ставови експерата квалитета по питању граничних вредности за одређивање усаглашености производа. Проблем са конекцијом се односио на то да се након покретања апликације за снимање слика прекине конекција без икаквог обавештења па се дешавало да уколико се процес снимања слика не проверава редовно на крају дана добије свега пар снимљених слика уместо пар стотина. Проблем неравномерне учесталости свих типова дефеката се односи на то да су одређени типови дефеката иницијално заузимали 80% скупа података а одређени мање од 1%. То је значило да је процес прикупљања слика трајао више дана, јер се дешавало да од снимљених 600 слика већина буде оних које су већ заступљене у скупу података, те такве слике није било корисно додавати у скуп слика које би се користиле за обуку модела. Проблем различитих ставова експерата квалитета се огледао у томе да експерти нису имали јединствен став које делове би требало прогласити усаглашеним, а које неусаглашеним у случају граничних вредности, поготово када је било речи о преливању лепка и оштећењима. Одлукама експерата су додељени исти пондери и на основу више-критеријумске класификације су донете коначне одлуке о усаглашености делова.

Слике су на различите начине припремане за модел класификације и за модел детекције дефеката, па је сваки процес описан у одговарајућем сегменту овог поглавља. У моделу класификације је било потребно само складиштити слике у одговарајући фолдер (усаглашене или неусаглашене). У моделу за детекцију типа и локације дефеката је било потребно аотирати све слике, односно заокружити на свакој слици сваки појединачни дефект, и доделити му одговарајућу класу.

4.2.4 Први ниво: Класификација слика

Путем коришћења *Keras* и *TensorFlow* библиотека, развијен је модел за утврђивање да ли је део усаглашен. На основу анализе слика делова, овај модел може класификовати производе у две категорије - исправне и неисправне. Коришћењем напредних алгоритама за учење, систем се оспособљава да аутоматски открива недостатке и мане на деловима без детекције типа дефекта. Развијени модел се показао као робустан и јако прецизан па је коришћен за класификацију слика са производне линије, где би моделу за детекцију типа и позиције дефекта предао само слике које прогласи неусаглашеним.

4.2.4.1 Развој и тренирање модела

У овом сегменту рада биће приказан поступак припреме слика и тренирање модела за класификацију усаглашених и неусаглашених производа. За сваки од описаних корака приложен је и део кода прилагођен за потребе овог рада.

Први део кода (Код 4.2.4.1 1 у прилогу) обрађује слике помоћу библиотеке "PIL" (енг. *Python Imaging Library*) и изводи следеће операције: Увози се неопходна функционалност: „**Image**“ из библиотеке "PIL" и „**os**“ за рад са оперативним системом. Подешава се директоријум који садржи изворне слике помоћу променљиве „**image_dir**“. Подешава се директоријум у који ће бити сачуване исечене слике помоћу променљиве „**cropped_dir**“. Ако овај директоријум не постоји, он се креира. Подешавају се координате за исечање слика помоћу променљиве „**box**“. У овом случају, слике ће бити исечене на димензију дефинисану координатама (0, 0) до (1020, 760). Петља пролази кроз све слике у директоријуму „**image_dir**“. Проверава се да ли је тренутни формат датотеке подржан формат слике, односно да ли има екстензију ".bmp". Ако је слика у траженом формату, отвара се помоћу „**Image.open()**“. Слика се исеца на основу подешених координата помоћу „**crop()**“ функције. Слика се конвертује у PNG формат помоћу „**convert()**“ функције. Исечена слика се чува у директоријуму „**cropped_dir**“ под новим именом помоћу „**save()**“ функције. Овај код ће исећи и конвертовати све слике у директоријуму **image_dir** на задате координате и сачувати их у директоријуму „**cropped_dir**“ у PNG формату са префиксом "cropped_" у новом имену датотеке.

Следећи део кода (у прилогу Код 4.2.4.1-2) користи OpenCV библиотеку да примени адаптивни и Оцуов „**thresholding**“ на слике из "images_cropped" директоријума. За сваку слику, примењују се следеће операције: учитавање као монохроматска слика, подешавање контраста и осветљења, адаптивни и Оцуов праг („**thresholding**“). Обрађене слике чувају се у "images_cropped_processed" директоријуму са одговарајућим именима фајлова. „**Thresholding**“ је поступак који се користи у обради слика како би се сегментовали делови слике који су од интереса за анализу или детекцију. У основи, „**thresholding**“ примењује праг или границу на интензитете пиксела у слици и раздваја пикселе који имају вредности изнад тог прага од оних који имају вредности испод тог прага.

На пример, у бинарној „**thresholding**“ операцији, сви пиксели са интензитетом већим од одређеног прага добијају вредност 1 (бела боја), док сви пиксели са интензитетом испод прага добијају вредност 0 (црна боја) (Al-amri et al., 2010). Овакав поступак омогућава издвајање објеката од интереса од позадине или других објеката на слици и лакшу анализу одабраних делова слике. У наредном делу кода (у прилогу Код 4.2.4.1-3) се увозе све библиотеке које ће бити потребне за даље тренирање модела. У коду у прилогу 4.2.4.1-4 дефинишу се локације фолдера у којим асе налазе слике за тренирање модела, валидацију као и тестирање модела. Пред тога дефинисане су путање за чување тренираних модела. Обзиром да сваки сачувани модел мора имати јединствени назив примењен је начин именовања фајлова заснованог на садржају временског печата у називу фајла (у прилогу Код 4.2.4.1-5). У коду у прилогу 4.2.4.1-6 се учитава претренирани модел VGG16 и замрзавају се сви слојеви базног модела. Структура модела је следећа:

```
model = Sequential([
    Conv2D(3,(3,3),padding='same'),
    base_model,
    Flatten(),
    Dense(64, activation='relu'),
    Dense(32, activation='relu'),
```

Dense(1, activation='sigmoid')

Након тога, додаје се нови класификациони слој са активационом функцијом "sigmoid". Модел се компајлира користећи алгоритам оптимизације "adam", функцију губитка "binary_crossentropy" и метрику "accuracy" за бинарну класификацију. У коду 4.2.4.1-7 се дефинишу генератори података за тренинг, валидацију и тестирање модела. Користи се „**ImageDataGenerator**“ за аугментацију и нормализацију слика. Параметри аугментације укључују ротацију, померање по ширини и висини, зумирање и хоризонтално инвертовање:

```
„augmentation_parameters = {  
    'rotation_range': 10,  
    'width_shift_range': 0.1,  
    'height_shift_range': 0.1,  
    'shear_range': 0.1,  
    'zoom_range': 0.1,  
    'horizontal_flip': True“.
```

Ови генератори података се користе за тренирање и тестирање модела са сликама из одговарајућих директоријума. Осим тога, дефинишу се **TensorBoard** и **ModelCheckpoint callback**-ови. **TensorBoard** се користи за визуализацију података обучавања, док се **ModelCheckpoint** користи за чување најбољег модела на основу тачности на валидационом скупу. У коду у прилогу 4.2.4.1-8 се тренира модел користећи генераторе података „**train_generator**“ и „**validation_generator**“ кроз 10 епоха. Током тренинга, користе се „**TensorBoard**“ и „**ModelCheckpoint**“ callback-ови за визуализацију мета података тренинга, и чување најбољег модела на основу тачности на валидационом скупу података. Након завршеног тренинга, модел се чува помоћу „**tf.saved_model.save()**“ функције у директоријуму „**model_save_path**“. Касније, најбољи модел се оцењује на тест скупу слика помоћу функције „**model.evaluate()**“, а затим се исписује тачност резултата тог модела на тест скупу слика.

Када се добије сачувани тренирани модел, он се може покренути по жељи без потребе за чекањем на тренинг модела кроз одређени број епоха. Трајање тренинга може зависити од комплексности кода, конфигурације на којој се тренинг врши, броја слика, броја епоха, комплексности архитектуре модела и још много тога. На рачунару просечне канцеларијске конфигурације, тренирање модела приказаног у овом сегменту би трајало неколико сати.

4.2.4.2 Тестирање и евалуација модела

Како би се утврдила успешност тренирања модела неопходно је упоредити његова предвиђања са истинитим ознакама слика из скупа за тест. У овом делу кода (у прилогу Код 4.2.4.2-1) модел се учитава из сачуваног „.h5“ фајла користећи „**tf.keras.models.load_model()**“. Затим се извршава петља за претраживање слика у скупу слика за тест. За сваку слику, извршава се следеће:

- Слика се учитава помоћу OpenCV функције „**cv2.imread()**“.
- Припрема се слика за предикцију: нормализује се и проширује са одговарајућим димензијама (додавање додатних димензија).
- Извршава се предикција помоћу учитаног модела користећи „**model.predict()**“.
- Исписују се информација о идентификационом броју слике (ID), ознаци (label) која одговара класи слике и предвиђеним вредностима (prediction) модела за ту слику.

Овај процес се понавља за све слике у тест скупу и добијени предвиђени резултати и тачне ознаке класа исписују се на екрану.

У овом случају су ти резултати јако задовољавајући. Са високим степеном прецизности модел је предвидео класе слика у скупу за тест. На Слици 4.2.4.2-1 приказан је идентификациони број сваке појединачне слике, њена истинита класа, и предвиђање исказано нумеричком вредношћу. Што је вредност предикције ближа нули, то је модел сигурнији да слика представља класу нула, односно лош комад. Што је вредност предикције ближа броју 1, то је модел сигурнији да је класа слике 1, односно да је комад усаглашен. Што би значило да вредност предикције 0,996 показује да је модел 99% сигуран у то да слика припада усаглашеном скупу, односно класи 1.

ID: cropped_Image009.png / Label: 0 / Prediction: [[2.5964584e-05]]	ID: cropped_cropped_Image1015.png / Label: 1 / Prediction: [[0.9884099]]
ID: cropped_Image011.png / Label: 0 / Prediction: [[9.896181e-06]]	ID: cropped_cropped_Image1111.png / Label: 1 / Prediction: [[0.9992212]]
ID: cropped_Image129.png / Label: 0 / Prediction: [[1.635027e-05]]	ID: cropped_cropped_Image1113.png / Label: 1 / Prediction: [[0.9961843]]
ID: cropped_Image1689.png / Label: 0 / Prediction: [[0.00489733]]	ID: cropped_cropped_Image1118.png / Label: 1 / Prediction: [[0.81303304]]
ID: cropped_Image1872.png / Label: 0 / Prediction: [[0.02326393]]	ID: cropped_cropped_Image1138.png / Label: 1 / Prediction: [[0.9736511]]
ID: cropped_Image198.png / Label: 0 / Prediction: [[1.8805625e-07]]	ID: cropped_cropped_Image1143.png / Label: 1 / Prediction: [[0.99791914]]
ID: cropped_Image2223.png / Label: 0 / Prediction: [[0.13217276]]	ID: cropped_cropped_Image1148.png / Label: 1 / Prediction: [[0.99348396]]
ID: cropped_Image2253.png / Label: 0 / Prediction: [[0.00755513]]	ID: cropped_cropped_Image1294.png / Label: 1 / Prediction: [[0.98106754]]
ID: cropped_Image2781.png / Label: 0 / Prediction: [[0.00010216]]	ID: cropped_cropped_Image1384.png / Label: 1 / Prediction: [[0.9788625]]
ID: cropped_Image2789.png / Label: 0 / Prediction: [[0.00035136]]	ID: cropped_cropped_Image1389.png / Label: 1 / Prediction: [[0.98732996]]
ID: cropped_Image3175.png / Label: 0 / Prediction: [[0.00521843]]	ID: cropped_cropped_Image1391.png / Label: 1 / Prediction: [[0.9993518]]
ID: cropped_Image478.png / Label: 0 / Prediction: [[5.091563e-06]]	ID: cropped_cropped_Image1395.png / Label: 1 / Prediction: [[0.9964767]]
ID: cropped_Image587.png / Label: 0 / Prediction: [[0.00011863]]	ID: cropped_cropped_Image1408.png / Label: 1 / Prediction: [[0.9734036]]
ID: cropped_Image750.png / Label: 0 / Prediction: [[6.1595224e-06]]	ID: cropped_cropped_Image1414.png / Label: 1 / Prediction: [[0.9874751]]
ID: cropped_Image888.png / Label: 0 / Prediction: [[2.0192238e-05]]	ID: cropped_cropped_Image1491.png / Label: 1 / Prediction: [[0.9672779]]
ID: cropped_Image890.png / Label: 0 / Prediction: [[4.8811864e-05]]	ID: cropped_cropped_Image1508.png / Label: 1 / Prediction: [[0.892922]]
ID: cropped_Image901.png / Label: 0 / Prediction: [[0.00092638]]	ID: cropped_cropped_Image1517.png / Label: 1 / Prediction: [[0.9874357]]
ID: cropped_image1004.png / Label: 0 / Prediction: [[2.3784834e-05]]	ID: cropped_cropped_Image1519.png / Label: 1 / Prediction: [[0.9916612]]
ID: cropped_image1025.png / Label: 0 / Prediction: [[4.4687935e-05]]	ID: cropped_cropped_Image1522.png / Label: 1 / Prediction: [[0.97757053]]
ID: cropped_image1053.png / Label: 0 / Prediction: [[1.0820108e-05]]	ID: cropped_cropped_Image1611.png / Label: 1 / Prediction: [[0.9605094]]
ID: cropped_image1352.png / Label: 0 / Prediction: [[6.0081387e-05]]	ID: cropped_cropped_Image1621.png / Label: 1 / Prediction: [[0.8923154]]
ID: cropped_image1371.png / Label: 0 / Prediction: [[9.719564e-05]]	ID: cropped_cropped_Image1624.png / Label: 1 / Prediction: [[0.9968502]]
ID: cropped_image1375.png / Label: 0 / Prediction: [[3.9658633e-07]]	ID: cropped_cropped_Image1628.png / Label: 1 / Prediction: [[0.9963689]]
ID: cropped_image1493.png / Label: 0 / Prediction: [[5.0129285e-05]]	ID: cropped_cropped_Image1638.png / Label: 1 / Prediction: [[0.9789684]]

Слика 4.2.4.2-1 Приказ истинитих класа слика и предвиђених класа од стране тренираног модела

Обзиром да су резултати постигнути тренингом модела за класификацију више него задовољавајући са прецизношћу преко 99% следећи корак је који би донео вредну информацију у процесу контроле квалитета је детекција позиције и типа дефекта.

4.2.5 Други ниво: Детекција објеката

Број усаглашених и неусаглашених производа у месечном извештају квалитета у данашње време није превише вредна информација без детаљних информација од неусаглашеним производима. Општи приступ управљању квалитетом смањује конкурентност на тржишту, те је битно имати детаљне извештаје од свим насталим дефектима у временском периоду који извештају обухватају. Знатно већу вредност има информација колико је било дефеката ког типа и на којим позицијама на производу су локализовани. На овај начин се добија увид у поузданост одређених производних процеса па је лакше приступити анализи корена узрока проблема, и смањити могућност

за настанак дефекта. Помоћу детекције објеката могуће је обучити модел да препознаје дефекте и аутоматски генерише извештај, нумерички, графички или графо-нумерички.

4.2.5.1 Претпроцесирање и анотирање слика

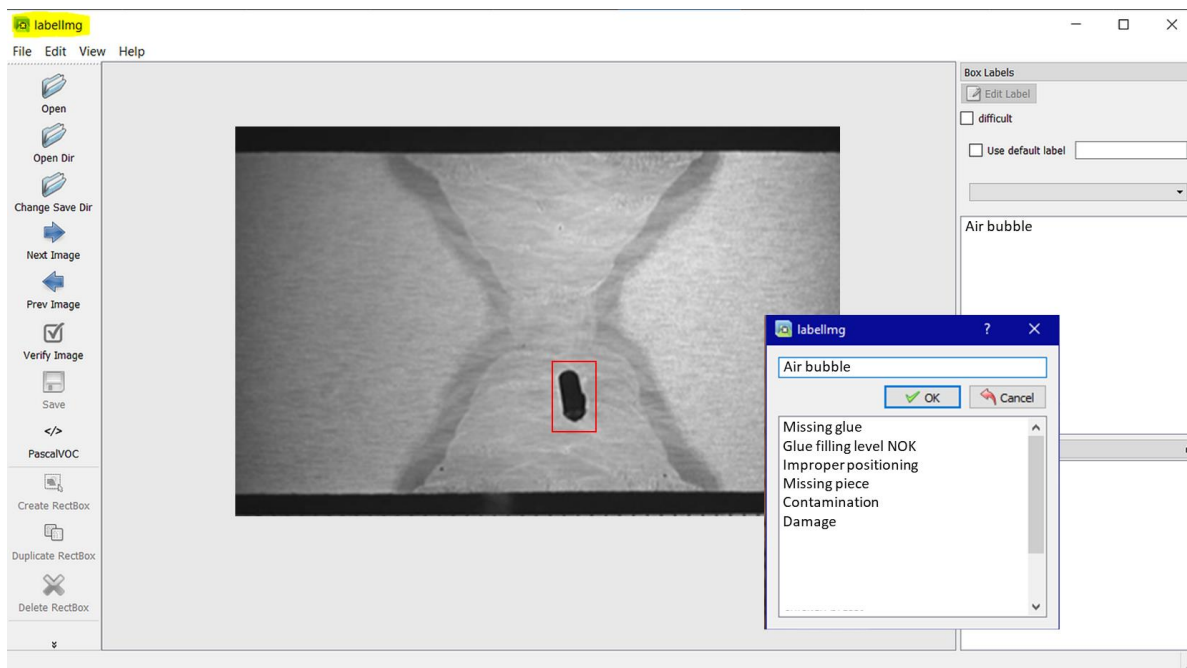
Анализом различитих приступа за детекцију објеката одабран је YOLO алгоритам због једноставности употребе кода, високе прецизности модела, могућности примене на фотографије и видео снимке, и велике количине претренираних модела (Terven and Cordova-Esparza, 2023). YOLOv8 је одабран као најробуснији модел за потребе овог пројекта, са највишим степеном прецизности у препознавању објеката. Да би се слике користиле у обуци YOLO модела потребно је да буду:

- у одговарајућој екстензији,
- сувишни делови слика могу бити уклоњени како не би збуњивали модел (непотребна позадина),
- у одговарајућој резолуцији (640*640),
- правилно осветљене и прилагођене.

Такође је потребно поделити скуп слика на три дела. Скуп за обуку модела, за валидацију и за тестирање модела након тренинга. У коду у прилогу 4.2.5.1-1 је приказан приступ конверзији слика у одговарајућу екстензију која на правилан начин функционише са моделом. Конверзија је примењена на сва три фолдера који су садржали поменуте скупове података. За скупове до пар хиљада слика независно од њихове величине овај процес траје релативно кратко, и за свега пар секунди све слике бивају конвертоване.

У наредном кораку се одстрањује вишак са слика, односно слика се опсеца како би у фокусу би само производ, без непотребне позадине где је год то могуће (у прилогу Код 4.2.5.1-2). Овај процес је примењен само на скуп за обуку како би се у валидационој и тест фази проверио рад модела са реалистичним улазним информацијама. Затим је потребно променити формат слика, које су иницијално биле форматирани у резолуцији 1280*1024 пиксела, у 640*640 јер је то формат који YOLO очекује и користи као подразумевану вредност у фази обучавања модела (Код у прилогу 4.2.5.1-3).

Како би се моделу олакшало разумевање предатих слика примењено је побољшање њихових графичких карактеристика, односно прилагођавање одређених параметара и конверзија слика у нијансе сиве. Ова побољшања су примењена такође само на скупу слика за обуку модела, не и на валидациони и тест скуп. Овим кораком је завршена припрема слика и било је потребно још анотирати све слике, из сва три скупа као што је приказано на Слици 4.2.5.1-1.



Слика 4.2.5.1-1 Приказ обележавања дефеката помоћу LabelImg апликације

За овај корак је коришћена апликација LabelImg са којом је могуће искупити проблеме уколико није инсталирана у одговарајућем програмском окружењу са компатибилном верзијом Python-а. Након усклађивања компатибилности апликације са окружење било је неопходно ручно означити све дефекте на свим сликама. Како је већ поменуто, слике неусаглашених делова су могле садржати више дефеката истог типа, више дефеката различитог типа, или пак само један дефект па их је све требало на тај начин и обележити.

4.2.5.2 Развој и тренирање модела

За примену YOLO модела је довољно инсталирати пакет „ultralytics“ и написати свега пар линија кода који би покренули тренирање алгоритма. Најједноставнији приступ је приказан у коду у прилогу 4.2.5.2-1 где је увежен претренирани модел, позвани су подаци из „.yaml“ фајла, задато је алгоритму да генерише приказ свих метрика у току тренинга и валидације, и захтевано да на једној слици изврши детекцију дефеката. Датотека са екстензијом „.yaml“ садржи податке о локација скупова података као и листу обележених дефеката на сликама, листу анотација. Дефинисано је да тренинг траје 10 епоха иницијално, али се број епоха прилагођава након анализе тенденција резултата по епохама на крају првог тренинга алгоритма. Тренирани модел ће бити сачуван како би касније могао бити коришћен. Трајање тренинга модела зависи од рачунарске конфигурације уколико се не ради на виртуелним машинама, броја слика, величине слика, броја епоха, итд. У овој поставци, са рачунаром канцеларијске конфигурације тренинг је трајао неколико сати у локалном окружењу.

У датотеци „dataset.yaml“ су дефинисане путање фолдера који садрже податке и набројано је 9 класа објеката. 8 класа представљају неусаглашености док 8. класа представља све усаглашене (OK) делове као што је приказано у коду у прилогу 4.2.5.2-2. У првом (пробном) кораку тренирања модела је одабран модел „S“ који се бира у линији кода „model = YOLO(“yolov8s.pt”)“ уписивањем одговарајућег слова након текста „yolov8“ где екстензија „.pt“ означава да је модел претрениран. Постоји више

величина YOLO модела где се они разликују у одређеним параметрима како је приказано на Слици 4.2.5.2-1.

Model	Size (pixels)	mAP val 50-95	Speed CPU (ms)	Speed T4 GPU (ms)	params (M)	FLOPs (B)
YOLOv8n	640	37.3	-	-	3.2	8.7
YOLOv8s	640	44.9	-	-	11.2	28.6
YOLOv8m	640	50.2	-	-	25.9	78.9
YOLOv8l	640	52.9	-	-	43.7	165.2
YOLOv8x	640	53.9	-	-	68.2	287.8

Слика 4.2.5.2-1 Приказ различитих YOLO модела (Github, 2020)

Након иницијалног тренинга и ревизије резултата приступљено је оптимизацији параметара за обучавање модела, повећавању броја епоха, као и величине модела. Параметри тренирања који су оптимизовани су приказани у коду у прилогу 4.2.5.2-3 и садрже низ подешавања која су се показали као најбољи, док су неки од њих наведени:

```
'epochs':80,
'batch':1,
'imgsz':1280,
'workers':4,
'lr0':0.01,
'lrf':0.002,
'momentum':0.937,
'weight_decay':0.0005,
'cls':0.6,
'dfl':1.5,
'label_smoothing':0.1,
'translate':0.1,
'scale':0.1,
'shear':0.0,
'perspective': 0.0,
```

Примењени модел је био YOLOv8x (обзиром да је у тренутку рада та верзија била најновија и оптимална за потребе пројекта) а број епоха је износио 50. Након сваког тренинга алгоритам је стварао нови фолдер који је садржао све резултате тренинга по епохама и фазама тренирања.

4.2.5.3 Тестирање и евалуација модела

Након сваког тренинга је генерисан нови извештај о успешности обучавања модела, што је интегрисана функција YOLOv8 алгоритма. У извештајима је недостајао визуелни приказ детектованих објеката на сликама у скупу података за тест, односно није било информације шта је тачно алгоритам и на ком делу слике идентификовао као дефект, те је било неопходно унапредити код. Након сваког тренинга обучени модел бива сачуван како би касније могао бити коришћен. У коду у прилогу 4.2.5.3-1 је учитан тренирани модел и захтевана је детекција објеката на сликама из одређеног скупа уз команду да све слике сачува у дефинисаном фолдеру са исцртаним квадратима на


местима где претпоставља да се налази дефект. На овај начин се добија визуелни приказ предвиђања модела и може се боље разумети да ли је неопходна оптимизација модела или не. Резултати који су добијени су били задовољавајући али је даља оптимизација неопходна.

У нормализованој матрици конфузије се може видети да модел одређене дефекте препознаје са апсолутном сигурношћу, док је за одређене дефекте степен сигурности био знатно нижи (Слика 4.2.5.3-1). Недовољно наливен лепак, не наливен лепак, неправилно позициониран део и недостајући део су били потпуно разумљиви за модел. Преливање лепка је било збуњујуће јер експерти квалитета производа нису дали јасне инпуте, те је при аотирању слика мање изражено преливање лепка обележавано као ОК део. И поред тога, преливање лепка је имало релативно висок резултат на тесту детекције облика. Мехур ваздуха, оштећења и контаминације су имале релативно низак резултат у матрици конфузије, а то је у највећој мери из три разлога. Први разлог је што се ова три типа дефекта јављају и више различитих позиција и облика, док се дефекти који имају висок резултат најчешће јављају у истом облику и на истом месту. На пример, контаминација може бити влакно, прашина, опиљак пластике или метала и тако даље, док је не наливен лепак увек присутан у истој форми. Други разлог је што су ови дефекти знатно мањих димензија од осталих дефеката. Као трећи и јадан од битнијих разлога, је недовољан број примера ових дефеката у скупу података за обучавање модела што се може видети на Слици 4.2.5.3-2.



Слика 4.2.5.3-1 Матрица конфузије тренираног модела

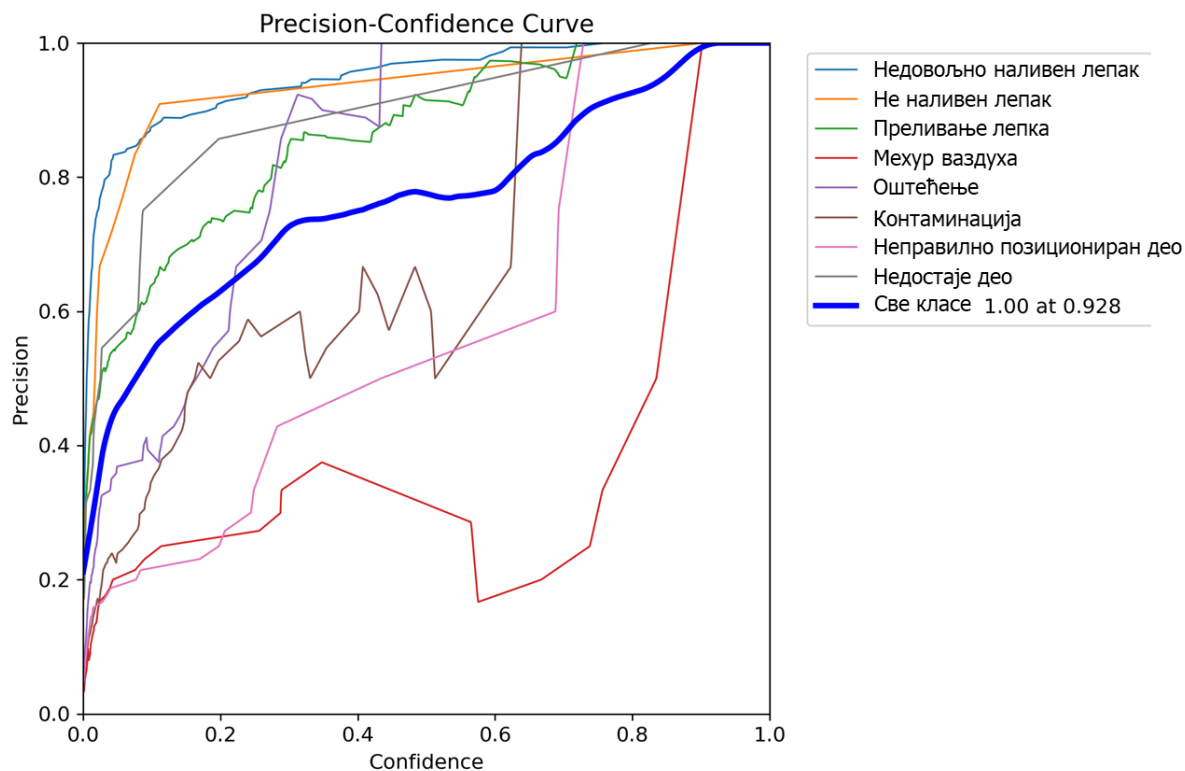
На Слици 4.2.5.3-2 се може видети заступљеност различитих класа дефеката у скупу података за обучавање модела. Приметно је да је скуп не избалансиран па је један од очигледних корака за унапређење модела прикупљање нових слика како би се избалансирао скуп података и повећао број слика за дефекте са лошијим резултатима у матрици конфузије.



Слика 4.2.5.3-2 Заступљеност различитих класа дефеката у скупу података за обучавање модела

График криве прецизности-поузданости (енг. *Precision-Confidence Curve*) представља визуелни приказ односа између прецизности модела и нивоа поузданости при предвиђању (Слика 4.2.5.3-3). У овој анализи, модел за машинско учење обично даје оцене уз вероватноће или уверености о правилности својих предвиђања за сваки објекат у тестираним подацима. Крива прецизности-поузданости нам показује колико је предвиђање модела било тачно у зависности од нивоа уверености модела. На графику, поузданост (вероватноћа, увереност) модела је приказана на хоризонталној оси, док је прецизност модела приказана на вертикалној оси. Поузданост је представљена као број између 0 и 1. Прецизност је представљена као пропорција тачних предвиђања у односу на укупан број предвиђања.

Овај график помаже да разумевању како се прецизност модела мења у односу на његову поузданост. Ако је модел веома сигуран у своја предвиђања (висок ниво поузданости), тада је пожељно имати и високу прецизност. Ако је модел мање сигуран у предвиђања (нижи ниво поузданости), тада је прихватљиво имати нижу прецизност. Ово график показује како утврдити оптимални праг (поузданости) за модел, где ће прецизност бити највиша.




Слика 4.2.5.3-3 Крива прецизности-поузданости модела

График криве прецизности и одзива (енг. Precision-Recall Curve) је важан алат за анализу перформанси модела (Слика 4.2.5.3-4). Он приказује однос између прецизности и одзива за различите вредности прага класификације. Прецизност представља однос тачно класификованих позитивних инстанци и укупно предвиђених позитивних инстанци. Са друге стране, одзив (Recall) представља однос тачно класификованих позитивних инстанци и укупно постојећих позитивних инстанци у подацима.

На графику, вредности прецизности су приказане на вертикалној оси, док је одзив приказан на хоризонталној оси. График представља криву која показује како се прецизност и одзив мењају за различите вредности прага класификације. Овај график је веома користан јер помаже да се проникне у перформансе модела за различите прагове и да се разуме његова способност да тачно класификује податке из обе класе (позитивне и негативне). Крива прецизности и одзива помаже да се пронађе оптимални праг класификације где ће бити постигнут најбољи баланс између прецизности и одзива.

Уколико се жели да модел буде што тачнији и да се максимизује прецизност, тражиће се вредности прага које дају високе вредности прецизности на графику. Са друге стране, уколико је одзив од великог значаја, можемо се тражити оптимална вредност прага која ће дати висок одзив.


График криве прецизности и одзива је користан алат за анализу перформанси класификационих модела и помаже при доношењу информисаних одлука о избору оптималних вредности прага класификације за конкретни задатак.



Слика 4.2.5.3-4 Крива прецизности и одзива модела

Крива F1-резултата и индекса сигурности (confidence) представља график који приказује однос између F1- резултата и индекса сигурности (confidence) за различите вредности прага класификације. F1- резултата је хармонична средина између прецизности и одзива (енг. *Recall*). Она представља меру тачности класификације у задацима са не избалансираним класима и приказује колико модел успешно препознаје и позитивне и негативне инстанце. Вредности F1- резултата се крећу између 0 и 1, где вредност 1 представља савршену класификацију, а вредност 0 представља потпуно неуспешну класификацију. Индекс сигурности (енг. *confidence*) односи се на сигурност или увереност класификатора у своје предвиђање. Када модел класификује неки улаз, индекс сигурности ће приказати колико је модел сигуран у тачност свог предвиђања за тај улаз. Индекс сигурности је обично вредност између 0 и 1, где вредност 1 представља апсолутну сигурност у предвиђању, док вредност 0 представља потпуно несигурност.


Крива F1- резултата и индекса сигурности приказује како се вредности F1- резултата мењају у односу на различите вредности индекса сигурности (Слика 4.2.5.3-5). Ово омогућава проналажење оптималне вредности прага класификације које ће дати највећи F1- резултат за одговарајући ниво индекса сигурности. Оваква анализа је корисна за решавање проблема не избалансираних скупова података и доношење одлука о избору оптималних параметара модела како би се постигао бољи баланс између прецизности и одзива, и максимизовао F1- резултат у зависности од нивоа сигурности предвиђања класификатора.



Слика 4.2.5.3-5 Крива F1-резултата и индекса сигурности

Крива одзива и индекса сигурности (confidence) представља график који приказује однос између одзива (recall) и индекса сигурности (confidence) за различите вредности прага класификације. Одзив (recall) представља однос правилно позитивно класификованих инстанци и свих инстанци које припадају позитивној класи. Он мери колико успешно модел препознаје позитивне инстанце из укупног скупа позитивних инстанци. Вредности одзива се такође крећу између 0 и 1, где вредност 1 представља савршен одзив, а вредност 0 представља потпуну неуспешност у препознавању позитивних инстанци.

Крива одзива и индекса сигурности приказује како се вредности одзива мењају у односу на различите вредности индекса сигурности (Слика 4.2.5.3-6). Ово помаже при одређивању оптималне вредности прага класификације која ће дати највећи одзив за одговарајући ниво индекса сигурности.



Слика 4.2.5.3-6 Крива одзива и индекса сигурности

Ако се узме у обзир да је детекција типа и позиције дефекта мање критичан задатак јер се примењује након класификације која има релативно високу прецизност овај пројекат се може затворити и са оваквим резултатима модела. Разумљиво је да је потребно прикупити више примера слика за дефекте са ниским резултатима и поново обучити модел. Анотирање слика, односно обележавање дефеката, је могло бити урађено на бољи начин. Приликом анотирања слика су дефекти који су били на границама толеранције остављени необележени како би их модел научио као ОК стања. Обзиром да класификација дефект већ добро „разуме“ граничне вредности толеранције могле би се у даљем раду поново анотирати слике где би се сви дефекти обележили. На пример, ако је мехур ваздуха мањи од 2 mm прихватљив чак и он би се требао обележити приликом анотирања слика. Приликом класификације првог нивоа, део који садржи мали мехур би био проглашен као ОК и не би ни стигао до другог нивоа класификације и одређивања типа дефекта. Ово би са друге стране смањило „збуњеност“ модела тиме што су исти облици некада класификовани као дефекти а некада као ОК стања. У случају даљег развијања овог модела хипер параметри могли додатно оптимизовати, архитектура модела адаптирати, и повећати број епоха. Такође би се могли очекивати бољи резултати при тренирању YOLO модела величине X. Обзиром да су ови резултати прихватљиви даљи развој модела у овом случају није спроведен али су документоване научене лекције за наредне пројекте.

4.2.6 Разматрања студије случаја

Ова анализа приказује значај унапређења застарелих система машинског вида коришћењем решења заснованих на вештачкој интелигенцији. Примена конволуцијских неуронских мрежа, као и разних Python библиотека као што су *Keras* и *Ultralytics* (YOLO) са циљем повећања тачности постојећег система машинског вида довела је до

смањења псеудо шкарта са 10% на 3%, што је резултирало значајним финансијским уштедама. Тачност модела је повећана са 90% на 97%. Прецизност решења износи 0.92, одзив 0.95, а F1 оцена 0.93 (Рајић et al., 2023b). Додатно, време подешавања и прилагођавања система машинског вида смањено је за 30%. Пројекат је остварио поврат инвестиција (ROI) за само 1.5 месец. У случају да је било потребе за новијим, адекватнијим рачунаром, ROI би износио 2 месеца, док би у случају потребе за једноставном новом камером заједно са рачунаром, ROI се кретао у опсегу од 2 до 4 месеца. Овде се мора узети у обзир велики распон цена камера које би се могле применити у овом конкретном пројекту.

Ово истраживање исказује да је унапређење постојећих система машинског вида помоћу решења вештачке интелигенције веома реално, и веома корисно. У одређеним случајевима, поврат инвестиција може бити веома брз, а контрола квалитета значајно унапређена. Додатно, неки пројекти могу захтевати нове рачунарске ресурсе и значајну количину времена, док у неким случајевима инвестиција у нову камеру може бити паметнији избор. Неопходно је имати одређено програмерско знање, али ову услугу је могуће и платити трећим лицима. Време и ресурси потребни за пројекат зависе од његове сложености. С аспекта контроле квалитета, најважније је имати детаљан преглед свих типова дефеката и њихових позиција на производу. У организацијама где су на располагању запослени са програмерским знањем, унапређење старих система машинског вида AI решењима може бити реализовано брзо и са ниским трошковима, што доноси значајне уштеде.

Студија случаја такође истиче важност прилагодљивости и флексибилности у суочавању са разноликим производним изазовима. Како се технологија и индустријске потребе мењају, способност брзог прилагођавања и усвајања нових метода и техника игра кључну улогу у осигурању конкурентности. Ово истраживање нуди увид у могућности које вештачка интелигенција пружа за унапређење квалитета и ефикасности у производној индустрији и омогућава организацијама да промисле о најбољим начинима за интеграцију ових технологија и донесу најбоље одлуке у погледу инвестиција и структуралних промена.

Студија случаја наглашава снажан потенцијал интеграције вештачке интелигенције у области контроле квалитета у оквиру индустријске револуције 4.0. Примена вештачке интелигенције у системима машинског вида не само да је донела значајна техничка и финансијска унапређења, већ и омогућила предвиђање и превенцију дефеката са више прецизности него икад пре. Резултати овог истраживања показују како се вештачка интелигенција, када се интегрише на адекватан начин, може претворити у моћно средство за повећање ефикасности и квалитета у производним процесима.

4.3 Потенцијали примене вештачке интелигенције у евалуацији купчевих захтева у аутомобилској индустрији

У аутомобилској индустрији, велика потреба за усавршавањем производње и постизањем високих стандарда квалитета утиче на произвођаче аутомобила да све више посвећују пажњу својим добављачима. Они, као кључни сарадници, имају битну улогу у процесу производње крајњег производа – моторних возила. Произвођачи аутомобила обично шаљу норме, процедуре и стандарде својим добављачима, који су прописани као захтеви за производњу компоненти. Овај поступак осигурава да се у процесу кооперације одржавају високи стандарди рада и константан квалитет производа.

Пре прихватања купчевих захтева, добављачи морају евалуирати сваки захтев и донети добро промишљену одлуку. Ово је кључни корак у процесу, јер одлука о прихватању или преговарању захтева директно утиче на успешност и ефикасност целокупног производног ланца. Евалуација купчевих захтева представља изазован посао, који зависи од различитих фактора, укључујући сложеност захтева, капацитете, техничке могућности и рокове завршетка. Стога, потреба за ефикасним методама и иновативним приступима у евалуацији ових захтева постаје суштински значајна.

У овом сегменту дисертације размотрена је потенцијална примена вештачке интелигенције као технолошког решења за евалуацију купчевих захтева у аутомобилској индустрији. Признајући предности и могућности које нуди вештачка интелигенција, испитују се начини на које овај тип технологије може допринети бржем, ефикаснијем и тачнијем процесу евалуације. Анализиране су могућности примене вештачке интелигенције у сарадњи произвођача аутомобила и њихових добављача, чиме би се олакшало и унапредило доношење одлука у комплексном и критичном процесу евалуације.

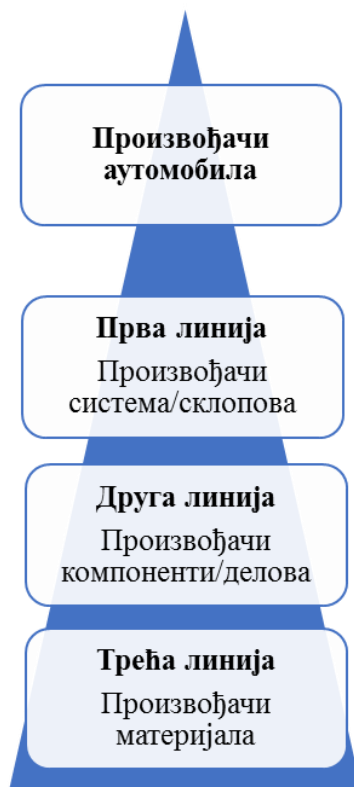
Употребом вештачке интелигенције у евалуацији купчевих захтева, ово истраживање настоји да пружи нове увиде и решења у области аутомобилске индустрије, унапређујући рад са добављачима и доприносећи оптимизацији процеса комуникације у целом ланцу снабдевања. Кроз примену вештачке интелигенције аутомобилска индустрија има могућност да дигитализује и унапреди процесе евалуације купчевих захтева, што би олакшало и убрзало дугорочне и скупе процесе.

У оквиру овог истраживања потенцијалне примене вештачке интелигенције у евалуацији купчевих захтева разматрана је ситуација у једној компанији која годинама уназад документује све завршене евалуације и преговоре са купцима. С обзиром на значајан обим података о завршеним евалуацијама, заједно са објашњењима и одлукама о прихватању или преговарању захтева, ова база података представља богату основу за тренирање модела вештачке интелигенције. Примена машинског учења и дубоког учења на овим подацима омогућила би израду прецизног модела вештачке интелигенције способног за ефикасну и прецизну евалуацију купчевих захтева, минимизирајући време и ресурсе укључене у овај процес.

Други важан аспект који треба размотрити је време и заузетост особа које евалуирају купчеве захтеве. Често су ови стручњаци на високим позицијама у Компанијама, обављају задатке са великом одговорношћу и њихово време је драгоцен ресурс. Ручно евалуирање купчевих захтева изискује значајно време и напор, а што додатно ограничава брзину и ефикасност процеса. Употребом вештачке интелигенције, ови експерти могли би ослободити део свог времена и ресурса, док би модел вештачке интелигенције са својом аутоматизованом евалуацијом захтева обезбедио брзу, сигурну и прецизну евалуацију.

4.3.1 Евалуација захтева купаца у аутомобилској индустрији

У оквиру аутомобилске индустрије разликујемо неколико врста производних ентитета. На врху пирамиде се налазе произвођачи аутомобила. То су компаније попут VW, GM, Daimler, FCA и PSA (сада спојени у STELANANTIS), и други. Следећи у низу би били добављачи из прве линије, односно добављачи који директно послују са произвођачима аутомобила, најчешће добављајући системе или склопове (Слика 4.3.1-1). Под системима и склоповима се мисли на јединицу система за грејање и хлађење, комплетан мотор СУС, комплетан електромотор, фар, седишта итд.



Слика 4.3.1-1 Приказ различитих производних ентитета у аутомобилској индустрији (Sehwi MARCOS Lee, 2018)

У оквиру аутомобилске индустрије, постоји три главна сегмента добављача који сарађују са произвођачима аутомобила. Прва линија добављача директно послује са произвођачем аутомобила и обезбеђује компоненте или делове неопходне за израду крајњег производа - моторних возила. Ови добављачи обично снабдевају компоненте као што су конектори, црева, цеви и слични елементи који чине кључне делове система или склопова у аутомобилу.

С друге стране, друга линија добављача нема директну пословну везу са произвођачем аутомобила, већ сарађује са првом линијом добављача. Они су одговорни за снабдевање прве линије добављача неопходним материјалима, деловима или компонентама. Ово укључује пружање различитих материјала и сировина неопходних за производњу компоненти које прва линија добављача испоручује произвођачу аутомобила.

У оквиру аутомобилске индустрије, трећа линија добављача представља значајну компоненту у производном ланцу, обезбеђујући компоненте или материјале који могу имати широк спектар примене у производњи моторних возила. Овај сегмент добављача

специјализован је за производњу различитих елемената неопходних у аутомобилској индустрији, укључујући гранулат разних пластика, жице, сензорске елементе, елементе електронике и друге напредне материјале. Они обезбеђују компоненте и материјале високог квалитета који се користе за израду различитих делова и система у аутомобилу. Добављачи из треће линије снабдевају произвођаче из друге линије добављача, обезбеђујући неопходне сировине, компоненте и материјале за производњу различитих делова. Ова врста сарадње обезбеђује ефикасан и оптимизован производни процес, где специјализовани произвођачи у трећој линији добављача прилагођавају своје производне капацитете потребама и захтевима друге линије добављача.

Предмет производње често може одступати од ове поделе у зависности од производног процеса произвођача аутомобила као и многих других фактора. Битно је разликовати директност, односно индиректност пословања добављача са произвођачем аутомобила. Може се узети пример произвођача електричних аутомобила који набавља електромотор од добављача из прве линије. Добављач из прве линије набавља бакарну жицу од добављача из друге линије. Добављач друге линије набавља бакар као сировину од добављача из треће линије.

У студији случаја о потенцијалној примени вештачке интелигенције у евалуацији купчевих захтева у аутомобилској индустрији, истражује се честа пракса произвођача аутомобила у вези са захтевима и уговорима о квалитету. Ови захтеви су усклађени са стандардом IATF 16949, али произвођачи аутомобила често имају додатне специфичне захтеве који дефинишу услове сарадње са њиховим добављачима. Према речнику квалитета „специфични захтеви“ произвођача аутомобила се разликују од „захтева“ произвођача аутомобила. Специфични захтеви произвођача аутомобила се налазе на разним интернет порталима (зависно од компаније) као и на сајту IATF-а (IATF, 2016). Специфични захтеви произвођача аутомобила су додатак захтевима стандарда IATF 16949, и добављачу заједно дају комплетну слику захтева. „Захтеви“ произвођача аутомобила (купчеви захтеви) могу бити везани за одређени производ, пројекат, производну локацију и самостални су документ.

Према стандарду IATF 16949, произвођачи аутомобила захтевају да сви њихови добављачи буду сертификовани према овом стандарду (IATF, 2016). Ово укључује примену одговарајућих оквира за управљање процесима унутар предузећа. Међутим, да би се захтеви комплетно дефинисали, произвођачи аутомобила имају и специфичне захтеве који су везани за њихове добављаче. Ови специфични захтеви се додају стандарду IATF 16949 и представљају допуну захтевима стандарда, што обезбеђује комплетну слику захтева којима се регулише сарадња између произвођача аутомобила и њихових добављача.

Купчеви захтеви, који могу бити у виду докумената који су самостални и везани за одређени производ или пројекат, представљају још један аспект сарадње у овој индустрији. Уз ове захтеве, постоје и разни уговори којима се дефинише начин сарадње између произвођача аутомобила и њихових добављача. Уговори о квалитету, пројектовању и развоју, набавци, финансијама и правним аспектима су само неки од примера. Овим уговорима се дефинише начин сарадње између две компаније. Захтеви купаца и разни уговори могу доћи на разне начине до добављача. Ова документа могу бити на купчевим порталима, могу бити послата путем електронске поште при склапању уговора за одређени пројекат или производну локацију, итд.

Овај камен спотицања у сарадњи међу актерима у индустрији може бити превазиђен употребом вештачке интелигенције. Аутоматизација евалуације купчевих захтева и уговора путем обучених модела вештачке интелигенције омогућила би брже и ефикасније одлучивање, што би у великој мери оптимизовало и убрзало процес снабдевања. Примена вештачке интелигенције у овом контексту би имала суштински

значај у подизању нивоа квалитета и ефикасности у индустрији, при чему би сарадња са добављачима била значајно унапређена и оптимизирана.

Сумирано, захтеви произвођача аутомобила/купаца ка добављачима могу се сврстати у неколико група:

- Захтеви стандарда
- Специфични захтеви купаца (ближе дефинишу захтеве из стандарда)
- Захтеви купаца (невезани за стандарде)
- Уговори везани за управљање разним процесима унутар компаније
- Уговори везани за одређени пројекат (толеранције, плаћања, материјали итд..)
- Уговори са правним захтевима

Већина ових захтева је усмерена ка првој линији добављача, јер са њима произвођач аутомобила потписује уговор о сарадњи. У зависности од организације и систематизације купца и типа захтева, ова документа могу доћи на различите начине до добављача. У зависности од организације и систематизације добављача, ова документа могу имати више запослених који се њима баве. Према захтевима стандарда IATF 16949 као и ISO 9001 за реализацију оперативних активности, утврђивање захтева за производе и услуге, преиспитивање захтева за производе и услуге као и спровођење измена и документовање процеса је обавезно (IATF, 2016).

Пример је сценарио у коме добављач, као компанија, обухвата више огранака или група производа, као што су електронске/електричне компоненте, вешање, трансмисије, издувни системи и слично. Захтеви купаца неће имати исти контекст нити тежину за сваку линију производа. Напротив, свака линија производа може захтевати различите стандарде или специфичности на које се уговори могу односити. Битно је и да различите толеранције не морају имати исти утицај на сваку линију производа. На пример, неке врсте производа би могле прихватити неку толеранцију без значајног утицаја на цену производње, док би иста толеранција могла значајно утицати на другу врсту производа.

Изазовност овакве ситуације настоји у томе што захтеви купаца обухватају разнолике и специфичне теме, захтевајући многе експерте из различитих области да их прегледају. У зависности од политике компаније добављача, купчеви захтеви могу бити прихваћени са или без анекса. Овај поступак додатно усложњава процес и подстиче потребу за ефикасним и рачунарски подржаним методама евалуације и управљања захтевима.

Примена вештачке интелигенције могла би значајно унапредити и оптимизовати овај процес. Развој модела вештачке интелигенције који би анализирали и процењивали различите аспекте купчевих захтева и уговора, и предлагали најбоље решење за сваки случај, имао би изузетан значај у повећању ефикасности и смањењу временских и трошкова ресурса. Уз помоћ вештачке интелигенције, добављачи би могли брже и ефикасније одговорити на захтеве купаца, преиспитати све релевантне стандарде и спецификације, и имплементирати готова решења у пословне процесе. Такав напредак би допринео бољој сарадњи са купцима, повећању квалитета производа и повећању конкурентности на тржишту. Сумирани процес имплементације купчевих захтева у аутомобилској индустрији састоји се из следећих корака:

- **Идентификација захтева и документације:** Процес почиње идентификацијом захтева и документације који су стигли преко различитих канала, укључујући интернет портале, сајтове и електронску пошту.
- **Провера релевантности захтева:** Затим се врши преглед унутар компаније добављача како би се утврдило за које групе или линије производа је документ релевантан.

- **Анализа области примене:** Документи се проверавају у оквиру различитих области примене, укључујући квалитет, производњу, логистику и друге аспекте.
- **Преиспитивање документације:** Захтеви и документи се прослеђују експертима из различитих области, група и линија производа на преиспитивање.
- **Синтеза резултата преиспитивања:** Резултати преиспитивања се прикупљају из свих релевантних области, група и линија производа.
- **Преговори са купцем:** Ако се уоче критични или нереалистични захтеви, врше се преговори са купцем ради усаглашавања.
- **Измене и допуне интерне документације:** На основу договора са купцем, врше се измене и допуне интерне документације добављача, укључујући процедуре, инструкције и обрасце за сваку групу или линију производа.

Овај процес омогућава да се захтеви купаца на ефикасан начин имплементирају у пословне процесе добављача, обезбеђујући да се сви купчеви стандарди и захтеви испуне на најбољи начин. Кроз сарадњу и преговоре са купцем, добављачи омогућавају оптималну сарадњу и усаглашеност унутар целокупног ланца снабдевања у аутомобилској индустрији.

Закључује се да је у великим компанијама ово дуготрајан процес који захтева ангажовање великог броја експерата, односно производи додатне трошкове. Последице не примењивања купчевих захтева у пословним процесима могу бити озбиљне по добављача. Може доћи до скупих рекламација, губитка сертификата или пословања са купцем. Недостаци овог приступа евалуацији купчевих захтева се између осталог огледају у:

- Дуготрајности и инертности процеса
- Потреби за „ручном“ провером портала и сајтова ради идентификације нових захтева/докумената
- Потреби за релативно великим бројем ангажованих експерата
- Потреби за обучавањем разних експерата о правилном приступу евалуацији
- Флукуацији експерата која ствара потребу за новом обуком
- Губитку научених лекција са променом евалуатора
- Неопходности да евалуатори консултују интерну документацију, стандарде, колеге или додатна документа на која се евалуирани документ позива
- Фактору људске грешке или субјективности
- Неопходности за „ручном“ изменом/ажурирањем постојеће интерне документације као и дистрибуцијом информације о изменама унутар организације

Код ове методе постоје и предности у односу на аутономно решење евалуације као што су:

- Једноставна и релативно кратка обука за евалуаторе
- Мањи ризик за штету нанесену потенцијалним сајбер нападом
- Усавршавање експерата кроз евалуацију разних захтева, стицањем „шире слике“
- При сумирању резултата евалуације могуће је консултовати евалуаторе ради додатних појашњења

Оба приступа носе одређене предности и мане, али се процес евалуације купчевих захтева од стране експерата показује као мање ефикасан.

4.3.2 Индустриска револуција 4.0 у оквиру евалуације захтева купаца у аутомобилској индустрији

Применом технологија које су описане у претходним поглављима је могуће знатно унапредити процес евалуације купчевих захтева. Људи у сусрету са новим приступом пословању могу бити неповерљиви, а уколико је реч неиспитаним технологијама чак и одбојни.

Ако се жели револуционисати процес евалуације купчевих захтева користећи технологије које носи Индустрија 4.0, мора се разумети да је податак/информација један од највреднијих ресурса данашњице. Могу се на пример при евалуацији купчевих захтева, захтеви класификовати као зелени, жути и црвени. Свака од ових категорија захтева би имала одређено значење и захтевала одређене радње:

Зелено – Идентификован је захтев који организација већ испуњава

Жуто – Идентификован је захтев који организација тренутно не испуњава и морају се предузети одређене радње зарад имплементације купчевог захтева

Црвено – Идентификован је захтев који организација не може испунити у датом облику и неопходни су преговори са купцем

У овој поставци би се алгоритму могли пружити низови претходно евалуираних купчевих докумената и резултата конвенционалне евалуације, те би систем могао да одређене конструкције реченица препозна као захтеве и додели им одређену вероватноћу за сваку од ове 3 категорије. Алгоритам би могао у ненадгледаном режиму да се сам калибрише или то може урадити експерт у подржаном режиму. Након обезбеђивања адекватне количине информација и калибрације система вештачке интелигенције, може се евалуацији подвргнути нови, непознати документ без претходно идентификованих резултата евалуације. У том другом нивоу прилагођавања је могуће подржаним режимом проверавати и додатно калибрисати систем. Након неког времена би систем могао функционисати са релативно високим степеном поузданости. Ако се проблему евалуације купчевих приступа у једној релативно великој компанији, може се закључити да се одређени кораци евалуације могу препустити вештачкој интелигенцији (ако не и у целисти).

Може се израдити алгоритам у који ће се учитати нови документ добијен путем електронске поште, али се може и израдити софтвер који ће претраживати претходно дефинисане интернет локације, упоређивати локалну базу прихваћених докумената и самостално преузимати нова документа. Код документа која се не налазе на интернет страницама због поверљивости података, могуће је у оквиру вертикалне интеграције договорити приступну тачку, попут једне дељене локације на којој би сви купци постављали поверљива документа која би софтвер самостално преузимао и класификовао. Провера релевантности документа за одређену групу или линију производа за одређеног купца може бити делимично или потпуно дигитализована. Дигиталном анализом документа би се могле извући кључне речи, док би се у бази података одређене кључне речи везале за сваку линију производа за сваког купца, респективно. Алтернативно решење је дефинисање релевантних особа унутар организације, које су ауторизоване да одреде релевантност документа, којима би софтвер слао захтев за изјашњење о релевантности. Евалуација документа би се обавила помоћу вештачке интелигенције која је претходно калибрисана комплетном историјом разних евалуација. Наспрам конвенционалне методе која може трајати месецима, овај процес би трајао неколико секунди или минута.

Укључивање графика унутар документа у еволуциони процес би се такође могло обавити како је описано у сегменту о препознавању слика. Резултат би био синтеза свих захтева из датог документа у једну табелу, а сваки захтев би био категоризован како је већ дефинисано. Да би се у почетној фази избегли пропусти алгорита, могуће је дефинисати и четврту категорију захтева у коју би спадали сви захтеви са којима се алгоритам до сада није сусретао или унутар интерне документације није било помена одређених појмова. Такође се систему вештачке интелигенције може обезбедити приступ складишту интерне документације са којом би се упоређивали захтеви из купчевих докумената. Уколико нпр. купчев документ дефинише да се у производњи уређаја који користе софтвер мора примењивати стандард *ASPICE*, који се није помињао ни у једном претходно анализираном документу (купчевом или интерном), тај захтев се може категорисати као поменута 4. категорија. Постоје разне могућности за процесирање оваквих захтева али као најједноставније, могуће је да се ови захтеви предају експертима унутар организације на евалуацију којом би се додатно калибрисао алгоритам. Са идентификацијом свих захтева из датог документа у категорисаној форми може се, уколико је то потребно, приступити преговорима са купцем ради преформулације одређених захтева.

Обзиром да је примена ових технологија још увек релативно ограничених могућности, а преговори укључују више различитих аспеката пословања и захтевају понекада доста вештине, у овом тренутку се преговори могу препустити експертима. Алтернатива би била да се алгоритму вештачке интелигенције обезбеди приступ нпр. електронској пошти експерата који воде преговоре и да се на основу историје кореспонденције састави нацрт/предлог преговора купцу.

Након преговора, или након евалуације ако нема потребе за преговорима, може бити потребно ажурирати интерну документацију у складу са купчевим захтевима и обавестити релевантне учеснике организације о датим изменама. Као и за претходну ставку, овај процес може бити конципиран тако да експерти преузимају договорену листу захтева и ручно ажурирају интерну документацију, да систем вештачке интелигенције самостално дистрибуира листу поменутих експертима у складу са предефинисаном листом или да се ради на развоју алгорита који би самостално ажурирао документацију.

Одређени период би се цео овај процес могао обављати у симулираном окружењу, затим у реалном окружењу у подржаном режиму и након тога у аутономном режиму. Ниво предаје овлашћења/задужења систему вештачке интелигенције, како је и описано, може бити парцијалан или потпун. Све ово су хипотезе у складу са сазнањима о могућностима технологије и реалним процесима евалуације купчевих захтева у аутомобилској индустрији.

Потенцијалне уштеде и предности које би организација могла остварити када систем буде адекватно калибрисан се између осталог односе на:

- Скраћено време од пријема до потписивања одређеног документа/уговора
- Елиминацију потребе за ручном провером портала и сајтова ради идентификације нових захтева/докумената
- Уштеду времена не ангажовањем људских ресурса из разних области у комплетном процесу
- Уштеду времена на обуци људских ресурса за евалуацију и преговоре
- Задржавање информација, сазнања, лекција и искустава која би се изгубила флукуацијом људских ресурса
- Свеобухватност/узимање у обзир информација о свим претходним евалуацијама и преговорима зарад доношења прецизније одлуке без елемента субјективности

- Свакако би овај приступ носио са собом и одређене недостатке и додатне трошкове, између осталог:
- Улагање у хардверске и софтверске ресурсе
- Већу озбиљност потенцијалног сајбер напада јер би поверљива документација била централизована
- Улагање у кадрове који би се бавили имплементацијом или подршком систему
- Улагања везана за хоризонталну и вертикалну интеграцију
- Ограничене могућности и ниво поузданости система
- Потенцијални недостатак образложења зашто су одређени захтеви класификовани као проблематични
- Потенцијално комплексан и дуготрајан процес имплементације и калибрације система вештачке интелигенције у процес евалуације купчевих захтева
- Потенцијални недостатак стручњака из области машинског учења и вештачке интелигенције на тржишту рада.

Битно је напоменути да овај процес захтева велики број технологија које се сматрају стубовима четврте индустријске револуције, а не само употребу вештачке интелигенције. Примена поменутих технологија у сврху преиспитивања техничких купчевих захтева није нарочито заступљена и релативно је тешко наћи радове који се баве датом тематиком. У врло сличном окружењу поједине компаније користе сличне процесе и технологије при евалуацији комерцијалних и правних уговора. Америчка компанија JP Morgan је покренула примену вештачке интелигенције при евалуацији уговора (Schaefer, 2019). Применом система за евалуацију, само на преиспитивању уговора о комерцијалним позајмицама су уштедели преко 360.000 радних часова правног тима у току прве године (Son, 2021).

Постоји неколико компанија на тржишту која пружају техничка решења за аутономну компјутерску евалуацију уговора, најчешће комерцијалних и правних. Неке од компанија су *Onit*, *Icertis* и сличне (Icertis, 2020; Onit, 2020). *Onit* обезбеђује пре евалуацију уговора и скраћују време евалуације (Onit, 2020). *Icertis* нпр. нуди цео спектар могућности укључујући и процес преговора (Icertis, 2020). Иако првенствено базирани на правне и комерцијалне уговоре, међу својим корисницима услуга *Icertis* убраја: *Daimler*, *Porsche*, *Continental*, *Airbus*, *Google* (Icertis, 2020)...

4.3.3 Разматрања на основу извршене студије случаја

Свака индустријска револуција је донела значајне промене, али су промене које се дешавају у оквиру четврте индустријске револуције учесталије и револуционарније него раније. Како је и приказано у овом сегменту рада, последњих година је развијен низ нових технологија које ће тек створити свој спектар примене и остварити свој потенцијал у скоријој будућности. Идеја аутономне дигиталне евалуације купчевих захтева је само један од примера употребе нових технологија у револуцији индустријских и административних процеса. Узевши у обзир све технолошке стубове 4. индустријске револуције, може се закључити да је ово тек иницијална фаза.

Применом нових технологија зарад оптимизације, појефтињења, скраћења трајања одређених процеса компанија постаје конкурентнија на тржишту и повећава свој профит. Међусобна повезаност уређаја унутар компаније знатно поједностављује одређене процесе и може обезбедити податке у реалном времену за које би се конвенционалним методама морало чекати на ручно прикупљање података и израду

извештаја. Транспарентност информација обезбеђује брз проток података унутар организације и олакшава њихову обраду као и процес одлучивања. Техничка подршка рачунарских система експертима при обављању њихових активности може значајно скратити време трајања одређених процеса и повећати њихову ефикасност и ефективност. Децентрализовано одлучивање омогућава експертима да одлуке које су „очигледне“ и понављајуће препусте рачунарским системима, не трошећи своје време на њих, фокусирајући се на комплексније задатке.

Преиспитивање захтева купаца је битан сегмент, нарочито у аутомобилској индустрији, који може изискивати доста времена, знања и искуства. Обзиром да су експерти који могу преиспитивати захтеве купаца често на високим позицијама унутар организације, може се претпоставити да је њихово време изузетно вредан ресурс. Применом вештачке интелигенције у процесу преиспитивања купчевих захтева могу се значајно смањити трошкови комплетног процеса, скратити време трајања евалуације и адекватније чувати и користити научене лекције. Примена вештачке интелигенције у преиспитивању купчевих захтева у аутомобилској индустрији није знатно заступљена али јесте у евалуацији правних и комерцијалних уговора у другим индустријским областима. Обзиром да је окружење слично а да у складу са захтевима стандарда резултати преиспитивања морају бити чувани формира се чврста основа за примену вештачке интелигенције у преиспитивању купчевих захтева у аутомобилској индустрији.

Потенцијални недостаци овог приступа су: дуготрајност израде и калибрисања система вештачке интелигенције, неопходност софтверске и хардверске инфраструктуре, немогућност алгорита вештачке интелигенције да пружи образложење одређене одлуке, недостатак стручњака из области вештачке интелигенције итд. Битно је разумети да се превазилажењем свих ових недостатака формира систем који је може бити неупоредиво ефикаснији и ефективнији од било које организације преиспитивања купчевих захтева конвенционалним методама.

4.4 Могућности примене вештачке интелигенције у обезбеђењу квалитета ласерски заварених спојева

Ласерско заваривање представља значајан поступак у индустријским процесима, обезбеђујући ефикасно спајање материјала без додавања додатног метала. Међутим, обезбеђивање квалитета ласерски заварених спојева представља изазов за произвођаче, посебно у условима растућих стандарда и комплексних захтева клијената. Традиционалне методе контроле квалитета засноване на визуелном уочавању дефеката и анализи спојева показале су се несигурним и временски захтевним.

У овом сегменту дисертације истражена је примена вештачке интелигенције као алтернативног приступа у обезбеђивању квалитета ласерски заварених спојева. Представљен је уводни преглед конвенционалних метода контроле квалитета ласерских заварених спојева, укључујући методе ИБР, оптичке системе и рачунарску обраду података. Приказани су различити приступи и методе у примени вештачке интелигенције у контроли квалитета ласерски заварених спојева.

Приказана је примена вештачке интелигенције у контроли квалитета ласерски заварених спојева кроз пар успешних примера документованих у научним радовима скоријег датума. Ови примери демонстрирају како вештачка интелигенција може допринети повећању ефикасности, тачности и прецизности у контроли квалитета, доводећи до повећања производне ефикасности и задовољства клијената у индустријским окружењима. Овај сегмент дисертације има за циљ да пружи увид у примену вештачке интелигенције у области ласерског заваривања и инспирише даља истраживања у овој области.

4.4.1 Уводна разматрања студије случаја

Постизање одређеног стандарда квалитета захтева узимање у обзир неколико фактора: техничких, технолошких и економских. Услови рада и опрема, распоред производње, као и трошкови инспекције, испитивања и поправки утичу на квалитет производа (Tavodová et al., 2020). Исти критеријуми могу се применити и на процену квалитета заварених спојева. Међутим, када је у питању заваривање, кључно је контролисати и пратити цео процес, јер грешке могу бити честе, а последице могу бити озбиљне и скупе (Tavodová et al., 2020).

Развој вештачке интелигенције и распрострањеност њене примене резултирао је све већим утицајем на производну индустрију (Sassi et al., 2019). Предности аутоматских поступака у односу на ручни рад повећале су популарност примене апликација вештачке интелигенције у процесима производње, посебно контроли квалитета (Sassi et al., 2019). Имплементација модела машинског учења у индустријску квалитету показала се веома корисном јер доприноси уштеди ресурса, времена и новца (Fahle et al., 2020). Неколико примера примењених ML модела у поступцима контроле квалитета наведено је у овом поглављу.

Грешке, односно дефекти при евалуацији квалитета ласерског заваривања могу се класификовати као интерни или екстерни (Tavodová et al., 2020). Спољне грешке могу се уочити голим оком или помоћу лупе, јер се јављају на површини материјала (Tavodová et al., 2020). Унутрашње грешке могу се открити тек након металографске анализе узорака. Ове грешке се јављају испод површине материјала. Неки од најчешћих дефеката код заваривања су:

- пукотине,
- шупљине,

- чврсте инклузије,
- недостатак фузије и пенетрације завара,
- неправилан облик и димензија завара.

Параметри ласерског заваривања морају се пажљиво пратити током процеса јер директно утичу на квалитет завара (Gao et al., 2017). На пример, анализом и контролом параметара као што су снага ласера, брзина заваривања и величина ласерског снопа, могуће је предвидети појаву грешака у заваривању (Wang et al., 2020). Такође, процесни параметри одређују геометрију пресека завара која утиче на геометрију и квалитет комплетног завара (Vänskä et al., 2013).

4.4.2 Примена вештачке интелигенције у контроли квалитета ласерски заварених спојева

Методе засноване на вештачкој интелигенцији најчешће се користе за предвиђање, класификацију великог броја добијених података и у оптичкој инспекцији, када је потребна висока прецизност и тачност за временски захтевне и монотоне послове.

Пример оптичке инспекције засноване на методама машинског учења је откривање дефеката у полимер литијум-јонским батеријама (ПЛБ) које је извео Ма и сарадници (Ma et al., 2019). У овом случају, широко коришћени модел дубоког учења, конволуцијска неуронска мрежа, користи се за откривање пликова на листовима ПЛБ-а на основу слика (Fahle et al., 2020). Ово се може посматрати као проблем класификације слика (Ma et al., 2019). CNN користи хијерархијску структуру да постепено издваја напредне карактеристике из мање релевантних карактеристика, затим користи ове напредне карактеристике за класификацију слика и откривање дефеката на листовима ПЛБ-а са слика производа (Ma et al., 2019).

Даље коришћење метода машинског учења налази се у идентификацији основних узрока неуспеха и одступања квалитета. Локранц и сарадници користе Бајесову мрежу, облик пробабилистичког графичког модела, да представе зависност између различитих производних фаза (Lokrantz et al., 2018). Овај модел користи стручно знање и претходно забележене податке од стране експерата да би изводио закључке о основним узроцима одступања квалитета. Овакав оквир пружа могућност да се знање чува за даљу употребу и дистрибуира на друге производне локације.

Још један пример примене алата машинског учења постављен је од стране Сумеша и сарадника. Користили су два различита алгорита класификације, J48 и *Random Forest*, како би одредили квалитет завара на основу одговарајућег звучног лука (Sumesh et al., 2015). Улазни параметри за класификатор били су звучни сигнали снимљени током експеримената, а касније генерисани у *Matlab* софтверу. Тачност *Random Forest*-а износила је 88,69%, а J48 70,78% (Sumesh et al., 2015). Иако су резултати били задовољавајући, према Сумешу и сарадницима, још увек постоји простор за побољшање перформанси алгоритама усавршавањем услова у којима се снима звучни лук.

4.4.3 Конвенционалне методе контроле квалитета ласерског заваривања

Ласерска технологија заваривања присутна је у индустрији више од 40 година и значајно је допринела побољшању ефикасности и прецизности заваривања (Tsukamoto, 2003). Овакви развоји технологија омогућавају већу флексибилност у производњи

(контролу над дизајном) и стога повећавају распон корисних својстава материјала која се могу произвести. Међутим, ласерско заваривање захтева ригорозну контролу и стално праћење процеса како би се постигао висок стандард квалитета. Конвенционалне методе које се користе за процену квалитета завареног споја могу бити деструктивне или недеструктивне.

Деструктивни тестови се постижу механичким и структурним тестовима и пружају квантитативне показатеље квалитета завареног споја. Да би се одредила механичка својства заварених спојева, неопходно је направити контролне узорке према одговарајућем стандарду. Ови узорци се добијају сечењем малог дела завареног комада које је намерно остављено или израдом специјалних комада (контролних плоча) који се заварују користећи исти поступак и завариваче као и планирана конструкција (Meola et al., 2004). Неки од механичких испитивања укључују испитивање напрегнућем, савијање, мерење тврдоће, итд.

Да би се одредила структура завареног споја, врше се структурна (металографска) испитивања. Узорци који се користе за ова испитивања припремају се брушењем и полирањем, након чега се површина узорка третира одређеним супстанцама (Tsukamoto, 2003). Избор хемијског реагенса који се користи за поменути третман заснива се на материјалу испитиваног објекта. Овим поступком могуће је видети макроскопски изглед завареног споја, као и микро структуру у зонама разређења завареног споја.

С друге стране, недеструктивно испитивање подразумева детекцију и процену одступања како на површини, тако и у унутрашњости материјала. Имајући у виду чињеницу да је скоро немогуће постићи заварени спој без било каквих дефеката, важно је одредити њихов облик и димензије. Дефекти заваривања се не сматрају неусаглашеностима ако се процени да се налазе унутар дозвољених граница прописаних захтевима квалитета завареног споја. Током ових испитивања, материјал се не оштећује на било који начин. Неки од најчешћих недеструктивних испитивања су визуелна испитивања, испитивање течним пенетрантима, магнетно-флуksно испитивање, ултразвучно испитивање и рендгенски преглед.

Деструктивне и недеструктивне методе обично захтевају пуно времена и додатних радних станица, специјализоване опреме и материјала, обучено особље, што резултира високим трошковима (Regaard et al., 2007).

4.4.4 Систем паметног осигурања квалитета у процесу ласерског заваривања

Алтернатива конвенционалним методама оцене квалитета налази се у развоју и интеграцији система за праћење процеса. Ови системи детектују грешке при заваривању током процеса, а негативни утицај неизвесних ометајућих фактора може се ефикасно смањити и дефектни делови се могу одвојити (Regaard et al., 2007).

Када је у питању ласерско заваривање, праћење процеса се спроводи у три фазе. У првој фази, током претпроцеса, прати се заварени шав (Wang et al., 2020). Након тога, током процеса се прати топљење материјала, грешке при заваривању, прскање, итд. Коначно, пост-процесно се испитује геометрија завара и видљиви дефекти.

Коришћењем метода заснованих на вештачкој интелигенцији, могуће је предвидети и прилагодити карактеристике завара, својства дефеката и стање завара (Cai et al., 2020). Такође, уколико је потребно, систем контроле може предложити корективне мере путем повратних информација, а цео процес постаје ефикаснији током времена јер прикупља све више података. Постоје различите методе које се користе за праћење процеса и оцену квалитета.

4.4.4.1 Технике надзора сигнала процесних сензора праћених помоћу вештачке интелигенције код ласерског заваривања

При надзору процеса, најчешће надзирани сигнали су акустични, оптички и термални. Сигнал акустичне емисије представља један начин за надзор процеса ласерског заваривања. Плазма која излази из металног купатила за време заваривања изазива флукуације притиска које стварају акустични сигнал (Cai et al., 2020). Овај сигнал се може мерити без контакта, користећи микрофон или резонантни сензор (Luo et al., 2019).

Акустични потписи, као што су одступање звучног притиска и снага фреквенцијског опсега, могу се користити за одређивање пропусности заваза применом алгорита неуронске мреже и метода регресивне анализе (Huang and Kovacevic, 2011). Алгоритми ефикасно раздвајају потпуну пропусност од делимичне пропусности материјала. Аутоматски систем мерења и контроле који су дизајнирали Лв и сарадници (Lv et al., 2014) доказао је да су акустични сигнали такође корисни за контролу дужине лука у реалном времену, на основу линеарног односа између звучног лука и дужине лука. Линеарни модел прилагођавања коришћен је за предвиђање висине топљене површине. Постигнути резултати предвиђања били су успешни. Главни недостатак овог приступа је подложност сигнала спољашњој буци, која се меша са акустичним сигналом заваривања (Cai et al., 2020). Међутим, ово се може избећи употребом метода смањења позадинске буке (Huang and Kovacevic, 2011) или коришћењем посебних система микрофона, који се састоје од осам микрофона у приказаном истраживању (Luo et al., 2016).

Оптички надзор сигнала се састоји од оптичког зрачења и оптичког визуелног надзора (Cai et al., 2020). Топљени метал, прскања и плазма емитују јако оптичко зрачење, а оптички сигнал оптичког зрачења првенствено потиче од ласерског зрака и зоне заваривања (Gao et al., 2015). На основу различитих таласних дужина, оптички сигнали зрачења могу се поделити на две категорије – UV (ултра љубичасто) и видљиво зрачење, где је таласна дужина 0,3 - 0,7 μm , и ИЦ (инфра-црвено) зрачење са опсегом таласних дужина између 1,1 μm и 1,6 μm (Haran et al., 1996). Опрема која се користи за детекцију оптичких сигнала зрачења обично укључује спектрометре, фото-диодне сензоре, камере високе брзине, CCD камере и CMOS камере (Cai et al., 2020). Ова метода надзора се често користи данас јер пружа велику количину поузданих података. На пример, (Kim and Ahn, 2012) је користио метод обраде слика при различитим условима заваривања како би се стекао увид у динамичко понашање завареног шавца, а (Tenner et al., 2015) је врло прецизно мерио брзину и смер протока течног материјала унутар шавца, постављајући стаклену плочу.

Резултати су показали везу између протока материјала и снаге ласера, брзине кретања сонде и ширине заваза (Tenner et al., 2015). Ипак, због просторних ограничења, сензор камере сигнала ограничен је у прикупљању података (Cai et al., 2020). Да би се избегао овакав недостатак и да би се могло извући довољно карактеристика за правилну оцену квалитета завареног споја, истраживачи се опредељују за више сензорских камера. На овај начин, зона заваривања може се надзирати из различитих углова и могу се добити квалитетне и детаљне информације о процесу заваривања и самом завареном споју.

Сигнал термалног зрачења је посебно јак у зони топљења материјала и високотемпературној металној пари, јер је температура и термално зрачење врло високо

у овим деловима зоне заваривања (Cai et al., 2020). Често коришћени сензори за добијање термалних сигнала су пирометар и ИЦ камера. Иако је пирометар јефтинији и једноставнији за интеграцију, ИЦ камера може прецизније детектовати расподелу температуре у зони заваривања. Сlike са ИЦ камере у зони топљења материјала коришћене су за процену ширине и дубине завареног споја [(Chandrasekhar et al., 2015; Chokkalingham et al., 2012). Анализом емитованог термалног зрачења, Веберпалс и сар. (Weberpals et al., 2011) испитали су расподелу температуре и геометријску структуру зоне заваривања. Овај приступ такође се може користити за дефинисање нагиба завареног шав.

4.4.4.2 Технике надзора процеса ласерског заваривања

Традиционалне методе надзора могу се поделити на два приступа - коаксијални и параксијални (Weberpals et al., 2011). Коаксијални метод надзора прати зону заваривања уградњом спектроскопа на пропагационом путу ласера (Kaierle, 2008). Добијени оптички и термални сигнали су стабилни и недвосмислени. Недостатак ове методе је недостатак флексибилности и комплексност уградње надзорног сензора. С друге стране, параксијални надзор се одликује лако прилагодљивом удаљеношћу надзорног сензора и углом између зоне заваривања и сензора. Ове традиционалне методе често представљају основу за нове методе надзора и фузију технологије више сензора.


Нове методе надзора, као што су рендгенска анализа, линијска кохерентна слика (ICI), магнето-оптичко испитивање (МОИ), итд., постигле су добре резултате у откривању одређених карактеристика заваривања, које су обично тешке за детектовање у току самог процеса (Cai et al., 2020). Ове карактеристике, као што је дубина завареног шав на пример, веома су корисне при оцењивању квалитета завареног споја јер су са њим тесно повезане.

Рендгенска видеографија може добити временски и просторно дефинисане информације о геометрији завареног шав у току процеса заваривања (Vänskä et al., 2013). Ова метода такође може служити за идентификацију унутрашњих дефеката завареног споја са високом просторном и временском резолуцијом. Коришћењем система за рендгенску дифракцију, микроструктура и механичка својства завареног споја могу бити истражена (Yan et al., 2010), а расподела осталих напрегнућа у завареном споју могу бити измерена (Kong and Kovacevic, 2010).

Оптичка кохерентна томографија (ОСТ) је још једна нова техника. ОСТ је 3D технологија мерења за аутоматско ласерско заваривање. Она може послужити као основа за систем надзора у производној линији који се користи за добијање томографских геометријских мерења током процеса формирања завареног споја (Ackermann and Schmitt, 2017).

Техника МОИ заснована је на принципу магнетне индукције и Фарадајевом ротационом ефекту (Xia et al., 1990). Експеримент је показао да микроструктура завареног споја може бити истражена помоћу МОИ методе, и то без металографске припреме (Gao et al., 2017).

Аутоматско надзирање процеса ласерског заваривања често се постиже коришћењем „посматрача“ заваривања (Слика 4.4.4.2-1). Анализом светлосног испуштања, створеног интеракцијом између ласера и материјала, „посматрачи“ заваривања могу препознати грешке у заваривању на основу претходно снимљених примера заваривања без дефеката (Gao et al., 2017).



Слика 4.4.4.2-1 „Посматрач“ процеса заваривања (4D, 2021)

Користећи паметне методе евалуације, посматрачи заваривања могу потпуно аутоматски сигнализирати премашивања граничних вредности одређених критеријума или параметара систему контроле.

Технологија фузије више сензора комбинује различите сензоре сигнала и користи предности сваког од њих (Wang et al., 2020). На тај начин, такав систем може ефективно и комплетно надзирати процес заваривања. Главни сензор ове технологије обично је видео сензор, јер обезбеђује детаљне информације о зони заваривања. Комбинација сензора варира у зависности од жељених резултата. На пример, рендгенски систем се може комбиновати са камером високе брзине (Volpp, 2017), звучни сензор са видео сензором (Wu et al., 2016), итд.

4.4.5 Успешни примери и могућности примене вештачке интелигенције у осигурању квалитета ласерског заваривања

Вештачка интелигенција може бити примењена на различите начине како би се осигурао квалитет заварених спојева, значајно смањујући трошкове испитивања, посебно у поређењу са методама деструктивних испитивања. Могућности су бројне, али неки од најзначајнијих би били надзор различитих параметара процеса помоћу вештачке интелигенције ради одређивања квалитета завареног споја, надзор оптичких сигнала током заваривања и примена вештачке интелигенције у обради и интерпретацији резултата за неке од конвенционалних метода контроле (као што је рендген). У овом поглављу су приказани неки успешни примери примене, као и кратка дискусија о истим.

Препознавање слика може се применити на различите начине у контроли квалитета заварених спојева. Грешке у заваривању могу бити откривене пратећи контуре зоне топлеења (линија топлеења и очвршћивања материјала). На овај начин могу се идентификовати различити дефекти, посебно недостатак фузије, односно спајања. За правилну поставку, истраживачи су користили CMOS камеру са додатним извором светлости и робусним алгоритмом за анализу слика. Приступ препознавања слика може се користити за откривање повратног оптичког сигнала ласера за време заваривања, топлотна камера се може користити за детекцију топлотних расподела у току заваривања, или могу се користити различити извори светлости за визуелну инспекцију

завареног споја у облику машинског вида (Chokkalingham et al., 2012; Gao et al., 2015; Ma et al., 2019; Regaard et al., 2007).

Надзор параметара процеса у циљу одређивања квалитета завареног споја може бити веома ефикасан приступ. Параметри процеса који нису визуелни могу се надзирати за време процеса заваривања. На пример, алгоритам вештачке интелигенције може бити обучен да прати температуру, напон, електричну струју, звук, притисак и многе друге параметре током заваривања и да на основу различитих комбинација вредности параметара одреди резултат заваривања (Cai et al., 2020; Regaard et al., 2007; Sumesh et al., 2015; Wu et al., 2016). Када је могуће, најекономичнији приступ је коришћење постојећих вредности мерења параметара процеса, без инвестиција у микрофоне или друге уређаје за мерење. Пример овог приступа је употреба адаптивног неуро-фазног инферентног система (ANFIS) и више-генског генетског програмирања (MGGP) за предвиђање квалитета ласерског заваривања, и откривање дефеката попут шупљина на површини, чврстине заваза итд. (Chatterjee et al., 2022).

Обрада и интерпретација резултата помоћу вештачке интелигенције је користан метод за уклањање дуготрајног ручног рада, чини процес ефикаснијим и омогућава брже добијање резултата испитивања. Испитивања помоћу вртложних струја, ултразвучна испитивања, рентгенска или компјутерска томографија (СТ) могу да пруже веома комплексне резултате. За људе може бити досадно да анализирају, компликовано да разумеју и интерпретирају ове резултате, а поступак може трајати јако дуго. Ако се на пример скенирањем СТ снимка ласерског завареног споја анализирају поре у материјалу, оператор треба да претрагом снимка пронађе поре, измери их и направи извештај. Многи системи за скенирање имају интегрисану функционалност вештачке интелигенције за анализу порозности материјала, али ако је потребно израчунати лом производа услед замора материјала изазваног порозношћу материјала, потребно је обавити бројне прорачуне. Истраживачи су покушали да предвиде оштећење услед замора материјала изазвано порозношћу ласерски заварених спојева, где би алгоритам вештачке интелигенције могао бити веома користан алат за повећање тачности предвиђања и смањење времена испитивања (Badora et al., 2021; Wu et al., 2015).

4.4.6 Разматрања студије случаја

У овом раду пружена је прегледна слика примене вештачке интелигенције у индустријској контроли квалитета, са фокусом на обезбеђењу квалитета ласерског заваривања. Дати су основи процеса ласерског заваривања, као и конвенционалних метода контроле квалитета ласерски заварених спојева. Конвенционални методи испитивања могу бити скупи и временски захтевни, посебно деструктивни методи испитивања. Данашње стање технологије омогућава боља решења. Модели предвиђања помоћу машинског учења или решења за надзор процеса помоћу вештачке интелигенције могу пружити резултате испитивања у реалном времену у брзим производним окружењима са веома ниским инвестицијама и са ниским трошковима испитивања.

Кроз различите примере примене вештачке интелигенције у осигуравању квалитета ласерског заваривања показује се да постоји велики потенцијал за унапређење конвенционалних система контроле квалитета, смањење трајања испитивања, смањење трошкова испитивања, унапређење прецизности откривања дефеката и још много тога. Вештачка интелигенција може успешно бити примењена за надзор различитих сигнала или параметара процеса ласерског заваривања у циљу одређивања квалитета завареног споја, у случајевима када се ласерско заваривање надзире са неким системима визије, вештачка интелигенција се може применити у препознавању слика зарад побољшања прецизности детекције грешака, или ако се примењује конвенционални метод контроле

квалитета (као што је рендген), вештачка интелигенција се може користити за обраду и интерпретацију резултата испитивања, јер то може бити временски захтеван процес за оператера.

Закључак

У оквиру индустријске револуције 4.0, примена вештачке интелигенције у контроли квалитета показала се као значајан напредак у области индустријске производње. Кроз различите студије случаја и примену алгоритама машинског учења и машинског вида, ова дисертација истражује како вештачка интелигенција може подржати и унапредити контролу квалитета у различитим производним процесима.

Примена модела машинског учења у предвиђању исхода процеса лемљења бакарних намотаја и примена машинског вида за класификацију и детекцију дефеката при наливању лепка за спајање у аутомобилској индустрији представљају конкретне примере унапређења контроле квалитета. Ови нови приступи доприносе ефикасности, смањењу грешака и бржој анализи дефеката у производним процесима.

Истраживање такође показује потенцијал примене вештачке интелигенције у евалуацији купчевих захтева у аутомобилској индустрији, смањујући временске и ресурсне захтеве у овом процесу. Додатно су размотрене могућности примене вештачке интелигенције у обезбеђењу квалитета ласерски заварених спојева, које доносе нове приступе и технологије за подизање стандарда квалитета у овој области.

Као резултат овог истраживања, демонстрирана је снажна веза између вештачке интелигенције и контроле квалитета у оквиру индустрије 4.0. Интеграцијом вештачке интелигенције у производне системе, остварују се бржи, ефикаснији и квалитетнији производни процеси. Овај напредак има потенцијал да промени садашње стандарде у индустријским окружењима и донесе бројне предности како за произвођаче, тако и за потрошаче. Како технологија вештачке интелигенције наставља да напредује, остаје велика могућност за додатни напредак и унапређење у контроли квалитета у будућности.

Примена алгоритама машинског учења и машинског вида пружа могућности за аутоматизацију, бржу анализу дефеката, а такође и могућности предвиђања исхода и оптимизације производних процеса. На основу добијених резултата, приметно је да употреба вештачке интелигенције у контроли квалитета има значајан утицај на ефикасност, смањење отказа и редукацију трошкова у производњи. Такође, увођење система заснованих на вештачкој интелигенцији може унапредити радни процес, побољшати робусност производње и створити конкурентску предност на тржишту. Један од најзначајнијих аспеката вештачке интелигенције у контроли квалитета је могућност обраде великих скупова података, што омогућава анализу и процену квалитета у реалном времену. То отвара пут ка бржем доношењу одлука и бржим реакцијама на промене у производњи.

У будућности, потребно је континуирано истраживати и развијати алгоритме и моделе вештачке интелигенције, усмерене ка проблемима контроле квалитета, како би се добили још бољи и надограђени системи. Додатно, потребно је разматрати етичке и безбедносне аспекте примене вештачке интелигенције, нарочито када је у питању контрола квалитета у специфичним индустријским областима.

Ова дисертација пружа значајан допринос у разумевању и примени вештачке интелигенције у области контроле квалитета. Пронађени резултати нуде увид у потенцијале ових технологија и потврђују да употреба вештачке интелигенције може суштински унапредити производне процесе и подићи стандарде квалитета у индустријским окружењима. Са континуираном подршком и развојем, овај технолошки напредак има потенцијал да трансформише начин управљања процесима производње и квалитета у променљивим условима модерне индустрије 4.0.

Кроз теоријски и практични рад пружени су одговори на основне хипотезе докторске дисертације од којих се пошло на основу постављеног циља истраживања:

- **(X1) Може се развити напредни систем за контролу квалитета применом напредних технологија попут вештачке интелигенције у *Lean* индустријском окружењу, који резултира бољим перформансама.**

На примеру аутомобилске индустрије, доказано је да је употреба вештачке интелигенције у развијеном систему за детекцију дефеката при наливању лепка знатно смањила ниво псеудо шкарта са 10% на само 3%, што представља значајну економску уштеду. Овај приступ је такође примењен и на операцију лемљења бакарних намотаја на фазне прстенове на статорима, где је доказано да је предвиђањем исхода операције лемљења могуће ефикасно смањити трошкове контроле квалитета и значајно скратити време тестова. Овај резултат је значајан не само у смислу уштеде ресурса, већ и у повећању квалитета крајњег производа. Такође, кроз предвиђање исхода операције лемљења на статорима је доказано да је помоћу вештачке интелигенције могуће смањити трошкове контроле квалитета, скратити време тестова и са релативно малим улагањима заменити статистичку контролу процеса контролом 100% производа.

Осим тога, анализом потенцијала вештачке интелигенције у области евалуације купчевих захтева и обезбеђења квалитета ласерски заварених спојева, истраживање је донело важне увиде у начине на које вештачка интелигенција може допринети процесима веће сложености. Теоретски концепт је допуњен примерима успешне примене, што нуди путоказ за будуће истраживаче и имплементаторе у овој области.

Свеукупно, ово истраживање не само што подржава основну хипотезу о могућности развоја напредних система за контролу квалитета коришћењем вештачке интелигенције, већ такође и открива нове путеве и могућности које ова иновативна област може отворити. Добијени резултати доприносе разумевању како вештачка интелигенција може преобразити индустријски сектор контроле квалитета и понудити решења која донесу знатне предности у ефикасности, сигурности и квалитету. С обзиром на постигнуте успехе и откривене потенцијале, ово истраживање нуди основу за даљи напредак и иновације у области примене вештачке интелигенције у контроли квалитета у индустријским окружењима.

- **(X2) Примена напредног система за контролу квалитета недеструктивног типа заснованог на примени вештачке интелигенције потенцијално може довести до повећања ефикасности и ефективности процеса контроле квалитета, кроз уштеде у процесу тестирања, скраћењем трајања тестова, пружањем бољег увида у квалитет производа или процеса, и унапређењем безбедности и здравља запослених.**

Ова хипотеза је покренута са циљем усмеравања пажње на могућности које вештачка интелигенција нуди у побољшању ефикасности, ефективности и безбедности унутар процеса контроле квалитета.

Кроз скраћено време трајања тестова, елиминацију потребе за уништавањем производа, олакшано подешавање и одржавање система за контролу квалитета доказано је да се применом вештачке интелигенције процеси контроле квалитета могу оптимизовати тако да постану ефективнији и ефикаснији. Такође, применом вештачке интелигенције је могуће прикупити више информација о квалитету производа, као и информација о већем броју производа јер се развијена решења заснивају на концепту контроле 100% производње а не на статистичку проверу.

Испитивање ове хипотезе донело је светле исходе, како се наглашава у одговору на хипотезу 1. Једна од значајних имплементација овог система односи се на предвиђање исхода процеса лемљења, где је деструктивни тест замењен алгоритмом вештачке интелигенције. Ово решење смањује потенцијалне ризике и опасности по здравље запослених, обезбеђујући алтернативу опасном раду и контакту са штетним супстанцама. Осим тога, прикупљање и анализа података о квалитету производа и

процеса постаје значајно ефикаснија и бржа уз помоћ вештачке интелигенције, што резултује у већем опсегу уштеда.

Елиминисањем потребе за ручним и потенцијално опасним радним задацима, вештачка интелигенција не само да доприноси повећању безбедности запослених, већ и доприноси квалитету производа. Бољи увид у квалитет производа и његових карактеристика омогућава боље одлучивање и брзе корекције аномалија, што додатно доприноси оптимизацији и ефикасности производних процеса.

У светлу свих добијених резултата, може се закључити да примена напредног система за контролу квалитета заснованог на вештачкој интелигенцији нуди не само економске предности кроз уштеде у ресурсима, већ и значајан напредак у области безбедности, здравља и општег квалитета радног окружења. Савремена индустријска пракса захтева непрекидно иновирање и унапређење, а управо ова хипотеза и њена потврда пружају основу за будућа истраживања и развој нових решења у области контроле квалитета.

• **(X3) Могуће је анулирати постојеће вишеструке препреке и отежавајуће околности за имплементацију напредног система за контролу квалитета недеструктивног типа заснованог на примени вештачке интелигенције у *Lean* индустријском окружењу у средњим и великим предузећима.**

Ова хипотеза, која се фокусира на превазилажење препрека на путу ка савременој индустријској примени вештачке интелигенције, донела је детаљан увид у потенцијалне проблеме и комплексност процеса.

Истраживање је идентификовало бројне чиниоце који могу утицати на успешност имплементације оваквих система. Недостатак хармонизованих и структурираних података из различитих извора, уз изазове повезивања на различите производне и информатичке системе, представља основни изазов. Сама природа складиштења индустријских података чини задатак филтрирања и прочишћавања неопходним. Подаци нису увек лако доступни, скоро увек морају бити филтрирани и прочишћени и нису увек једносмислени. При дефинисању граничних вредности за одређене дефекте може доћи до несугласица међу експертима па то може закомпликовати процес обележавања података, а и тренирање самог модела. Уколико се користе подаци које је човек ручно уносио грешке су врло честе и треба пажљиво прегледати све податке који се предају алгоритму. Све ове препреке је могуће превазићи али изискују доста времена и труда, а услед недостатка искуства у овом процесу овакве ствари имплементаторима могу промаћи и касније стварати велике проблеме при тренирању модела или интеграцији решења.

Поред тога, ово истраживање приказује дубоку синергију између експертних знања и вештачке интелигенције. Тренирање модела захтева посебну пажњу и стручност, како би се избегле грешке које се могу јавити ако се не узму у обзир сви аспекти пројекта као и скупова података. Овакве препреке и изазови, иако захтевни, несумњиво су допринели обогаћивању знања у области вештачке интелигенције и контроле квалитета у индустријским окружењима.

Истраживање је показало да је обука и развој модела у симбиози са структуром и елементима *Lean* индустријског окружења довела до значајних успеха. Од почетка до краја дисертације, активности су обухватиле развој концепта, прикупљање и анализу података, дизајн и имплементацију решења. Ова целокупна методологија пружила је увид у дугачак и комплексан процес који је завршен успешно, са конкретним доприносима у подручју вештачке интелигенције и квалитета у индустријским процесима.

Сажето речено, ова хипотеза дубоко је анализирала истраживачке изазове који прилазе уз интеграцију вештачке интелигенције у индустријско окружење, а

истовремено је показала успешне практичне резултате који потврђују вредност и знање стечено овим истраживањем.

Теоријски допринос овог рада се огледа у комплетирању слике која приказује свеобухватни спектар различитих технологија контроле квалитета које су недеструктивног типа, и то у оквиру и уз појашњење технолошких стубова Индустрије 4.0. Такође је дат структурирани преглед различитих могућности примене вештачке интелигенције у индустријском окружењу са фокусом на примену у контроли квалитета. Такође је практични допринос овог рада то што пружа комплетан увид, корак по корак, при имплементацији два реална индустријска пројекта унапређења која су горе поменута. Уз то дисертација пружа комплетан приказ развоја концепта примене вештачке интелигенције у евалуацији купчевих захтева као и обезбеђењу квалитета ласерски заварених спојева.

Кроз имплементацију решења за предвиђање исхода процеса лемљења, као и унапређења застарелих система за детекцију дефеката помоћу вештачке интелигенције је приказан цео процес од развоја концепта, прикупљања података, дизајна решења, развоја модела, и имплементације решења.

Сам процес развоја концепта и имплементације оваквих система приказује не само техничке аспекте вештачке интелигенције, већ и важност прецизности, стручности и савладавања различитих изазова. Ова фаза истраживања дубоко је анализирао не само како изградити ефикасан модел, већ и како га интегрисати у стварном свету, суочавајући се са свим изазовима који долазе са тим.

У целини, ова дисертација представља значајан прилог у области вештачке интелигенције и контроле квалитета у индустријским окружењима. Кроз теоретске и практичне аспекте, она обогаћује разумевање потенцијала вештачке интелигенције у овом домену и пружа важан увид у начине како се ова технологија може успешно интегрисати у реалном свету.

Овај истраживачки рад, иако структуриран и промишљен, није обухватио широки или дубоки обим свих метода и техника вештачке интелигенције, и покрива само оквири одабраних метода и техника. Ограничења која су присутна у овом раду, имају потенцијал да утичу на опсег и ширину интерпретације постигнутих резултата.

Прво, важно је напоменути да се овај рад, иако са значајним учинком, фокусира на само два конкретна аспекта примене вештачке интелигенције у контроли квалитета. Овакво фокусирање могло би ограничити општу слику о потенцијалним применама ове технологије у овом домену. Остали могући начини и приступи за примену вештачке интелигенције су ван оквира овог истраживања.

Друго, овај рад не разматра разноврсне платформе, апликације и алгоритме који би могли да буду коришћени у оквиру примене вештачке интелигенције у области контроле квалитета. Ово може довести до ограничености у погледу обухватања свих могућности и перспектива.

Треће, нагласак на реалним индустријским пројектима и практичним аспектима у истраживању може ограничити апликативну суштину овог рада. Док је фокус на примени решења на конкретним проблемима веома важан и мотивишући, то такође може ограничити опсег примене у различитим окружењима и индустријским областима.

Укратко, овај рад представља важан преглед и демонстрацију примене вештачке интелигенције у области контроле квалитета. Међутим, важно је имати на уму ограничења која прате овакве радове, као и могућност додатних истраживања и примена које се налазе изван обима овог истраживања.

Предложени путеви за даља истраживања у овој области обухватају широк спектар могућности за напредак и допринос развоју и примени вештачке интелигенције у области контроле квалитета и индустријске оптимизације.

Као први правац, будућа истраживања могу наставити усавршавање и оптимизацију постојећих решења која су развијена у оквирима ове дисертације. Ово подразумева дубљу анализу алгоритама и модела који су коришћени, и тражење начина како би се њихове перформансе додатно побољшале. Такође, може се истражити како додатно оптимизовати процес прикупљања и анализе података како би се омогућио бржи и ефикаснији процес унапређења квалитета.

Други могући правац је развој нових приступа и техника у домену вештачке интелигенције који су прилагођени специфичним изазовима контроле квалитета. Ово може укључивати истраживање нових алгоритама за анализу и предвиђање, креирање иновативних модела, и експериментисање са различитим техникама машинског учења.

Трећи правац даљег истраживања може се фокусирати на адаптацију и примену развијених решења у другим секторима индустрије. На пример, истраживање се може проширити на области као што су логистика, набавка, производња и продаја, и истражити како вештачка интелигенција може унапредити процесе рада у тим областима.

Са развојем Индустрије 4.0 и брзим напретком у области вештачке интелигенције, постоје бројне могућности за додатно истраживање и развој који могу допринети не само научном напретку, већ и примени технологија у реалним индустријским окружењима.

Литература

- 4D, 2021. Weld Watcher 4D.
- AbdAlla, A.N., Faraj, M.A., Samsuri, F., Rifai, D., Ali, K., Al-Douri, Y., 2019. Challenges in improving the performance of eddy current testing: Review. *Meas. Control* 52, 46–64. <https://doi.org/10.1177/0020294018801382>
- Abdallah, M., Abu Talib, M., Feroz, S., Nasir, Q., Abdalla, H., Mahfood, B., 2020. Artificial intelligence applications in solid waste management: A systematic research review. *Waste Manag.* 109, 231–246. <https://doi.org/10.1016/j.wasman.2020.04.057>
- Ackermann, P., Schmitt, R., 2017. Tomographical process monitoring of laser transmission welding with OCT, in: Lehmann, P., Osten, W., Albertazzi Gonçalves, A. (Eds.), . Presented at the SPIE Optical Metrology, Munich, Germany, p. 103290H. <https://doi.org/10.1117/12.2269108>
- Al-amri, S.S., Kalyankar, N.V., D., K.S., 2010. Image Segmentation by Using Threshold Techniques. <https://doi.org/10.48550/ARXIV.1005.4020>
- Ali, S.S., Choi, B.J., 2020. State-of-the-Art Artificial Intelligence Techniques for Distributed Smart Grids: A Review. *Electronics* 9, 1030. <https://doi.org/10.3390/electronics9061030>
- Anderson, D., McNeill, G., 1992. *Artificial Neural Networks Technology*. Kaman Sciences Corporation, New York.
- Andronie, M., Lăzăroiu, G., Iatagan, M., Uță, C., Ștefănescu, R., Cocoșatu, M., 2021. Artificial Intelligence-Based Decision-Making Algorithms, Internet of Things Sensing Networks, and Deep Learning-Assisted Smart Process Management in Cyber-Physical Production Systems. *Electronics* 10, 2497. <https://doi.org/10.3390/electronics10202497>
- Araujo, T., Helberger, N., Kruikemeier, S., De Vreese, C.H., 2020. In AI we trust? Perceptions about automated decision-making by artificial intelligence. *AI Soc.* 35, 611–623. <https://doi.org/10.1007/s00146-019-00931-w>
- Arifin, N.L., Widiastuti, H., Wibowo, A., 2018. Study on effect of source to film distance (SFD) on the radiographic images, in: 2018 International Conference on Applied Engineering (ICAE). Presented at the 2018 International Conference on Applied Engineering (ICAE), IEEE, Batam, pp. 1–4. <https://doi.org/10.1109/INCAE.2018.8579376>
- Azizi, A., 2019. *Applications of Artificial Intelligence Techniques in Industry 4.0*, SpringerBriefs in Applied Sciences and Technology. Springer Singapore, Singapore. <https://doi.org/10.1007/978-981-13-2640-0>
- Bacoup, P., Michel, C., Habchi, G., Pralus, M., 2018. From a Quality Management System (QMS) to a Lean Quality Management System (LQMS). *TQM J.* 30, 20–42. <https://doi.org/10.1108/TQM-06-2016-0053>
- Badora, M., Sepe, M., Bielecki, M., Graziano, A., Szolc, T., 2021. Predicting length of fatigue cracks by means of machine learning algorithms in the small-data regime. *Eksploat. Niezawodn. - Maint. Reliab.* 23, 575–585. <https://doi.org/10.17531/ein.2021.3.19>
- Belhadi, A., Mani, V., Kamble, S.S., Khan, S.A.R., Verma, S., 2021. Artificial intelligence-driven innovation for enhancing supply chain resilience and performance under the effect of supply chain dynamism: an empirical investigation. *Ann. Oper. Res.* <https://doi.org/10.1007/s10479-021-03956-x>
- Berg, L.P., Vance, J.M., 2017. Industry use of virtual reality in product design and manufacturing: a survey. *Virtual Real.* 21, 1–17. <https://doi.org/10.1007/s10055-016-0293-9>

- Bergmann, R.B., Bessler, F.T., Bauer, W., 2007. Non-Destructive Testing in the Automotive Supply Industry- Requirements, Trends and Examples Using X-ray CT.
- Bertagnolli, F., 2022. Lean management: introduction and in-depth study of Japanese management philosophy. Springer, Wiesbaden [Heidelberg].
<https://doi.org/10.1007/978-3-658-36087-0>
- Berthold, M., Borgelt, C., Höppner, F., Klawonn, F., Silipo, R., 2020. Guide to intelligent data science: how to intelligently make use of real data, Second edition. ed, Texts in computer science. Springer, Cham, Switzerland. <https://doi.org/10.1007/978-3-030-45574-3>
- Berthold, M.R., Cebron, N., Dill, F., Gabriel, T.R., Kötter, T., Meinl, T., Ohl, P., Sieb, C., Thiel, K., Wiswedel, B., 2008. KNIME: The Konstanz Information Miner, in: Preisach, C., Burkhardt, H., Schmidt-Thieme, L., Decker, R. (Eds.), Data Analysis, Machine Learning and Applications, Studies in Classification, Data Analysis, and Knowledge Organization. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 319–326. https://doi.org/10.1007/978-3-540-78246-9_38
- Bishop, C.M., 2006. Pattern recognition and machine learning, Information science and statistics. Springer, New York.
- Blecken, A., Zobel, A., Maurantzas, E., 2010. Development of a Lean Quality Management System: An Integrated Management System, in: Dangelmaier, W., Blecken, A., Delius, R., Klöpfer, S. (Eds.), Advanced Manufacturing and Sustainable Logistics, Lecture Notes in Business Information Processing. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 141–151. https://doi.org/10.1007/978-3-642-12494-5_13
- Blouin, A., Kruger, S., Monchalain, J.-P., 2008. Applications of Laser-Ultrasonics to the Automotive Industry.
- Borisov, V., Leemann, T., Seßler, K., Haug, J., Pawelczyk, M., Kasneci, G., 2022. Deep Neural Networks and Tabular Data: A Survey.
- Breitenbach, J., Dauser, T., Illenberger, H., Traub, M., Buettner, R., 2021. A Systematic Literature Review on Machine Learning Approaches for Quality Monitoring and Control Systems for Welding Processes, in: 2021 IEEE International Conference on Big Data (Big Data). Presented at the 2021 IEEE International Conference on Big Data (Big Data), IEEE, Orlando, FL, USA, pp. 2019–2025.
<https://doi.org/10.1109/BigData52589.2021.9671887>
- Brito, T., Queiroz, J., Piardi, L., Fernandes, L.A., Lima, J., Leitão, P., 2020. A Machine Learning Approach for Collaborative Robot Smart Manufacturing Inspection for Quality Control Systems. *Procedia Manuf.* 51, 11–18.
<https://doi.org/10.1016/j.promfg.2020.10.003>
- Buongiorno, D., Prunella, M., Grossi, S., Hussain, S.M., Rennola, A., Longo, N., Di Stefano, G., Bevilacqua, V., Brunetti, A., 2022. Inline Defective Laser Weld Identification by Processing Thermal Image Sequences with Machine and Deep Learning Techniques. *Appl. Sci.* 12, 6455. <https://doi.org/10.3390/app12136455>
- Cai, W., Wang, J., Jiang, P., Cao, L., Mi, G., Zhou, Q., 2020. Application of sensing techniques and artificial intelligence-based methods to laser welding real-time monitoring: A critical review of recent literature. *J. Manuf. Syst.* 57, 1–18.
<https://doi.org/10.1016/j.jmsy.2020.07.021>
- Calisir, F., Camgoz Akdag, H. (Eds.), 2018. Industrial Engineering in the Industry 4.0 Era, Lecture Notes in Management and Industrial Engineering. Springer International Publishing, Cham. <https://doi.org/10.1007/978-3-319-71225-3>
- Cardoso, D., Ferreira, L., 2020. Application of Predictive Maintenance Concepts Using Artificial Intelligence Tools. *Appl. Sci.* 11, 18. <https://doi.org/10.3390/app11010018>
- Carnegie Mellon |University, 2018. The " Only" Coke Machine on the Internet.

- Chandrasekhar, N., Vasudevan, M., Bhaduri, A.K., Jayakumar, T., 2015. Intelligent modeling for estimating weld bead width and depth of penetration from infra-red thermal images of the weld pool. *J. Intell. Manuf.* 26, 59–71. <https://doi.org/10.1007/s10845-013-0762-x>
- Changliang, S., Hao, Z., Shiyun, D., Weixue, T., 2017. Novel nondestructive testing applications in old automotive engine. *IOP Conf. Ser. Mater. Sci. Eng.* 182, 012060. <https://doi.org/10.1088/1757-899X/182/1/012060>
- Charron, R., Harrington, H.J., Voehl, F., Wiggin, H., 2015. *The lean management systems handbook, Management handbooks for results.* CRC Press, Boca Raton.
- Chatterjee, S., Mahapatra, S.S., Lamberti, L., Pruncu, C.I., 2022. Prediction of welding responses using AI approach: adaptive neuro-fuzzy inference system and genetic programming. *J. Braz. Soc. Mech. Sci. Eng.* 44, 53. <https://doi.org/10.1007/s40430-021-03294-w>
- Chen, A., Rotevatn, N., Nilssen, R., Nysveen, A., 2009. Characteristic investigations of a new three-phase flux-switching permanent magnet machine by FEM simulations and experimental verification, in: 2009 International Conference on Electrical Machines and Systems. Presented at the 2009 12th International Conference on Electrical Machines and Systems (ICEMS 2009), IEEE, Tokyo, pp. 1–6. <https://doi.org/10.1109/ICEMS.2009.5382791>
- Chen, Y., Wang, Q., Chen, H., Song, X., Tang, H., Tian, M., 2019. An overview of augmented reality technology. *J. Phys. Conf. Ser.* 1237, 022082. <https://doi.org/10.1088/1742-6596/1237/2/022082>
- Chien, C.-F., Dauzère-Pérès, S., Huh, W.T., Jang, Y.J., Morrison, J.R., 2020. Artificial intelligence in manufacturing and logistics systems: algorithms, applications, and case studies. *Int. J. Prod. Res.* 58, 2730–2731. <https://doi.org/10.1080/00207543.2020.1752488>
- Chokkalingham, S., Chandrasekhar, N., Vasudevan, M., 2012. Predicting the depth of penetration and weld bead width from the infra red thermal image of the weld pool using artificial neural network modeling. *J. Intell. Manuf.* 23, 1995–2001. <https://doi.org/10.1007/s10845-011-0526-4>
- Chung, S.-H., 2021. Applications of smart technologies in logistics and transport: A review. *Transp. Res. Part E Logist. Transp. Rev.* 153, 102455. <https://doi.org/10.1016/j.tre.2021.102455>
- Ciampa, F., Mahmoodi, P., Pinto, F., Meo, M., 2018. Recent Advances in Active Infrared Thermography for Non-Destructive Testing of Aerospace Components. *Sensors* 18, 609. <https://doi.org/10.3390/s18020609>
- Cioffi, R., Travaglioni, M., Piscitelli, G., Petrillo, A., De Felice, F., 2020. Artificial Intelligence and Machine Learning Applications in Smart Production: Progress, Trends, and Directions. *Sustainability* 12, 492. <https://doi.org/10.3390/su12020492>
- Clark, D.M., Silvester, K., Knowles, S., 2013. Lean management systems: creating a culture of continuous quality improvement. *J. Clin. Pathol.* 66, 638–643. <https://doi.org/10.1136/jclinpath-2013-201553>
- Computer History Museum, 2021. . *Comput. Hist. Mus.*
- Daniyan, I., Mpofu, K., Oyesola, M., Ramatsetse, B., Adeodu, A., 2020. Artificial intelligence for predictive maintenance in the railcar learning factories. *Procedia Manuf.* 45, 13–18. <https://doi.org/10.1016/j.promfg.2020.04.032>
- Devore, J.L., 2012. *Probability and statistics for engineering and the sciences*, Eighth edition. ed. Brooks/Cole, Cengage Learning, Boston, MA.

- Ding, L., Lu, Q., Liu, S., Xu, R., Yan, X., Xu, X., Lu, M., Chen, Y., 2022. Quality inspection of micro solder joints in laser spot welding by laser ultrasonic method. *Ultrasonics* 118, 106567. <https://doi.org/10.1016/j.ultras.2021.106567>
- Ding, R.-X., Palomares, I., Wang, X., Yang, G.-R., Liu, B., Dong, Y., Herrera-Viedma, E., Herrera, F., 2020. Large-Scale decision-making: Characterization, taxonomy, challenges and future directions from an Artificial Intelligence and applications perspective. *Inf. Fusion* 59, 84–102. <https://doi.org/10.1016/j.inffus.2020.01.006>
- Duan, Y., Edwards, J.S., Dwivedi, Y.K., 2019. Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. *Int. J. Inf. Manag.* 48, 63–71. <https://doi.org/10.1016/j.ijinfomgt.2019.01.021>
- Fahle, S., Prinz, C., Kuhlenkötter, B., 2020. Systematic review on machine learning (ML) methods for manufacturing processes – Identifying artificial intelligence (AI) methods for field application. *Procedia CIRP* 93, 413–418. <https://doi.org/10.1016/j.procir.2020.04.109>
- Fallah Madvari, R., 2023. Artificial Intelligence (AI), Machine Learning (ML) and Deep Learning (DL) on Health, Safety and Environment (HSE). *Arch. Occup. Health.* <https://doi.org/10.18502/aoh.v6i4.11727>
- Faragó, K.B., Skaf, J., Forgács, S., Hevesi, B., Lőrincz, A., 2022. Soldering Data Classification with a Deep Clustering Approach: Case Study of an Academic-Industrial Cooperation. *Appl. Sci.* 12, 6927. <https://doi.org/10.3390/app12146927>
- Fathi, M., Khakifirooz, M., Pardalos, P.M. (Eds.), 2019. Optimization in Large Scale Problems: Industry 4.0 and Society 5.0 Applications, Springer Optimization and Its Applications. Springer International Publishing, Cham. <https://doi.org/10.1007/978-3-030-28565-4>
- Fotouhi, S., Pashmforoush, F., Bodaghi, M., Fotouhi, M., 2021. Autonomous damage recognition in visual inspection of laminated composite structures using deep learning. *Compos. Struct.* 268, 113960. <https://doi.org/10.1016/j.compstruct.2021.113960>
- Frochte, J., 2021. *Maschinelles Lernen: Grundlagen und Algorithmen in Python, 3., überarbeitete und erweiterte Auflage.* ed, Plus.Hanser-Fachbuch. Hanser, München.
- Fu, G., Sun, P., Zhu, W., Yang, J., Cao, Yanlong, Yang, M.Y., Cao, Yanpeng, 2019. A deep-learning-based approach for fast and robust steel surface defects classification. *Opt. Lasers Eng.* 121, 397–405. <https://doi.org/10.1016/j.optlaseng.2019.05.005>
- Gadri, S., Chabira, S., Ould Mehieddine, S., Herizi, K., 2022. Sentiment Analysis: Developing an Efficient Model Based on Machine Learning and Deep Learning Approaches, in: Vasant, P., Zelinka, I., Weber, G.-W. (Eds.), *Intelligent Computing & Optimization, Lecture Notes in Networks and Systems.* Springer International Publishing, Cham, pp. 237–247. https://doi.org/10.1007/978-3-030-93247-3_24
- Galos, J., Ghaffari, B., Hetrick, E.T., Jones, M.H., Benoit, M.J., Wood, T., Sanders, P.G., Easton, M.A., Mouritz, A.P., 2021. Novel non-destructive technique for detecting the weld fusion zone using a filler wire of high x-ray contrast. *NDT E Int.* 124, 102537. <https://doi.org/10.1016/j.ndteint.2021.102537>
- Gao, X., Lan, C., You, D., Li, G., Zhang, N., 2017. Weldment Nondestructive Testing Using Magneto-optical Imaging Induced by Alternating Magnetic Field. *J. Nondestruct. Eval.* 36, 55. <https://doi.org/10.1007/s10921-017-0434-4>
- Gao, X., You, D., Katayama, S., 2015. The high frequency characteristics of laser reflection and visible light during solid state disk laser welding. *Laser Phys. Lett.* 12, 076003. <https://doi.org/10.1088/1612-2011/12/7/076003>
- Gilchrist, A., 2016. *Industry 4.0.* Apress, Berkeley, CA. <https://doi.org/10.1007/978-1-4842-2047-4>

- Github, 2020. Links, examples and additional information about Yolo v4.
- Golio, J.M. (Ed.), 2008. RF and microwave passive and active technologies, The electrical engineering handbook series. CRC Press, Boca Raton.
- Guirong, X., Xuesong, G., Yuliang, Q., Yan, G., 2015. Analysis and Innovation for Penetrant Testing for Airplane Parts. *Procedia Eng.* 99, 1438–1442. <https://doi.org/10.1016/j.proeng.2014.12.681>
- Gunal, M.M. (Ed.), 2019. Simulation for Industry 4.0: Past, Present, and Future, Springer Series in Advanced Manufacturing. Springer International Publishing, Cham. <https://doi.org/10.1007/978-3-030-04137-3>
- Hafiz, A.M., Hassaballah, M., Binbusayyis, A., 2023. Formula-Driven Supervised Learning in Computer Vision: A Literature Survey. *Appl. Sci.* 13, 723. <https://doi.org/10.3390/app13020723>
- Haghnegahdar, L., Joshi, S.S., Dahotre, N.B., 2022. From IoT-based cloud manufacturing approach to intelligent additive manufacturing: industrial Internet of Things—an overview. *Int. J. Adv. Manuf. Technol.* 119, 1461–1478. <https://doi.org/10.1007/s00170-021-08436-x>
- Hai, J., Xuan, Z., Yang, R., Hao, Y., Zou, F., Lin, F., Han, S., 2023. R2RNet: Low-light image enhancement via Real-low to Real-normal Network. *J. Vis. Commun. Image Represent.* 90, 103712. <https://doi.org/10.1016/j.jvcir.2022.103712>
- Hamade, R.F., Baydoun, A.M.R., 2019. Nondestructive detection of defects in friction stir welded lap joints using computed tomography. *Mater. Des.* 162, 10–23. <https://doi.org/10.1016/j.matdes.2018.11.034>
- Hao, R., Lu, B., Cheng, Y., Li, X., Huang, B., 2021. A steel surface defect inspection approach towards smart industrial monitoring. *J. Intell. Manuf.* 32, 1833–1843. <https://doi.org/10.1007/s10845-020-01670-2>
- Haran, F.M., Hand, D.P., Peters, C., Jones, J.D.C., 1996. Real-time focus control in laser welding. *Meas. Sci. Technol.* 7, 1095–1098. <https://doi.org/10.1088/0957-0233/7/8/001>
- Hartung, J., Elpelt, B., Klösener, K.-H., 2005. Statistik: Lehr- und Handbuch der angewandten Statistik ; mit zahlreichen, vollständig durchgerechneten Beispielen, 14., unwesentlich veränd. Aufl. ed. Oldenbourg, München Wien.
- Hauben, R., 1998. A Study of the ARPANET TCP/IP Digest and of the Role of Online Communication in the Transition from the ARPANET to the Internet.
- Heaton, J., Heaton, J., 2013. Deep learning and neural networks, Artificial intelligence for humans / Jeff Heaton. Heaton Research, Inc, St. Louis, MO.
- Helo, P., Hao, Y., 2022. Artificial intelligence in operations management and supply chain management: an exploratory case study. *Prod. Plan. Control* 33, 1573–1590. <https://doi.org/10.1080/09537287.2021.1882690>
- Honarvar, F., Varvani-Farahani, A., 2020. A review of ultrasonic testing applications in additive manufacturing: Defect evaluation, material characterization, and process control. *Ultrasonics* 108, 106227. <https://doi.org/10.1016/j.ultras.2020.106227>
- Hong, Y., Yang, M., Jiang, Y., Du, D., Chang, B., 2022. Real-time Quality Monitoring of Ultra-Thin Sheets Edge Welding Based on Micro-Vision Sensing and SOCIFS-SVM. *IEEE Trans. Ind. Inform.* 1–11. <https://doi.org/10.1109/TII.2022.3199258>
- Huang, W., Kovacevic, R., 2011. A neural network and multiple regression method for the characterization of the depth of weld penetration in laser welding based on acoustic signatures. *J. Intell. Manuf.* 22, 131–143. <https://doi.org/10.1007/s10845-009-0267-9>
- Husain, I., Ozpineci, B., Islam, M.S., Gurpinar, E., Su, G.-J., Yu, W., Chowdhury, S., Xue, L., Rahman, D., Sahu, R., 2021. Electric Drive Technology Trends, Challenges, and

- Opportunities for Future Electric Vehicles. *Proc. IEEE* 109, 1039–1059.
<https://doi.org/10.1109/JPROC.2020.3046112>
- Hwang, B., Hillmann, S., Schulze, M., Klein, M., Heuer, H., 2015. Eddy current imaging for electrical characterization of silicon solar cells and TCO layers, in: Meyendorf, N.G. (Ed.), . Presented at the SPIE Smart Structures and Materials + Nondestructive Evaluation and Health Monitoring, San Diego, California, United States, p. 94390D.
<https://doi.org/10.1117/12.2085302>
- IATF, 2016. IATF 16949:2016.
- Icertis, 2020. Contract management AI -pplications in negotiation [WWW Document]. URL <https://www.icertis.com/contract-management/ai-applications/negotiateai/> (accessed 7.23.23).
- Iglesias, G., Talavera, E., González-Prieto, Á., Mozo, A., Gómez-Canaval, S., 2023. Data Augmentation techniques in time series domain: a survey and taxonomy. *Neural Comput. Appl.* <https://doi.org/10.1007/s00521-023-08459-3>
- Jamil, M., Khan, A.M., Hegab, H., Sarfraz, S., Sharma, N., Mia, M., Gupta, M.K., Zhao, G., Moustabchir, H., Pruncu, C.I., 2019. Internal Cracks and Non-Metallic Inclusions as Root Causes of Casting Failure in Sugar Mill Roller Shafts. *Materials* 12, 2474.
<https://doi.org/10.3390/ma12152474>
- Jandyal, A., Chaturvedi, I., Wazir, I., Raina, A., Ul Haq, M.I., 2022. 3D printing – A review of processes, materials and applications in industry 4.0. *Sustain. Oper. Comput.* 3, 33–42. <https://doi.org/10.1016/j.susoc.2021.09.004>
- Jensen, R., Shen, Q., 2008. *Computational Intelligence and Feature Selection*. John Wiley & Sons, Inc., Hoboken, NJ, USA. <https://doi.org/10.1002/9780470377888>
- Ji, Y., Li, N., Cheng, Z., Fu, X., Ao, M., Li, M., Sun, X., Chowwanonthapunya, T., Zhang, D., Xiao, K., Ren, J., Dey, P., Li, X., Dong, C., 2022. Random forest incorporating ab-initio calculations for corrosion rate prediction with small sample Al alloys data. *Npj Mater. Degrad.* 6, 83. <https://doi.org/10.1038/s41529-022-00295-5>
- Jiang, H., 2021. *Machine Learning Fundamentals: A Concise Introduction*, 1st ed. Cambridge University Press. <https://doi.org/10.1017/9781108938051>
- Jo, T., 2021. *Machine learning foundations: supervised, unsupervised, and advanced learning*. Springer, Cham, Switzerland.
- Jovanović, M., Lazić, V., 2015. Tehnologija livenja zavarivanja. Mašinski fakultet, Kragujevac.
- Jung, A., 2022. *Machine Learning: The Basics, Machine Learning: Foundations, Methodologies, and Applications*. Springer Nature Singapore, Singapore.
<https://doi.org/10.1007/978-981-16-8193-6>
- Kaierle, S., 2008. Process Monitoring and Control of Laser Beam Welding: Measuring Quantifiable Data for Improved Processing Results. *Laser Tech. J.* 5, 41–43.
<https://doi.org/10.1002/latj.200890024>
- Kavis, M., 2014. *Architecting the cloud: design decisions for cloud computing service models (SaaS, PaaS, and IaaS)*, The Wiley CIO series. John Wiley & Sons, Inc, Hoboken, New Jersey.
- Kayan, H., Nunes, M., Rana, O., Burnap, P., Perera, C., 2022. Cybersecurity of Industrial Cyber-Physical Systems: A Review. *ACM Comput. Surv.* 54, 1–35.
<https://doi.org/10.1145/3510410>
- Kim, C.-H., Ahn, D.-C., 2012. Coaxial monitoring of keyhole during Yb:YAG laser welding. *Opt. Laser Technol.* 44, 1874–1880. <https://doi.org/10.1016/j.optlastec.2012.02.025>
- Kokol, P., Kokol, M., Zagoranski, S., 2022. Machine learning on small size samples: A synthetic knowledge synthesis. *Sci. Prog.* 105, 003685042110297.
<https://doi.org/10.1177/00368504211029777>

- Kong, F., Kovacevic, R., 2010. 3D finite element modeling of the thermally induced residual stress in the hybrid laser/arc welding of lap joint. *J. Mater. Process. Technol.* 210, 941–950. <https://doi.org/10.1016/j.jmatprotec.2010.02.006>
- Kumar, S., Gaur, V., Wu, C., 2022. Machine learning for intelligent welding and manufacturing systems: research progress and perspective review. *Int. J. Adv. Manuf. Technol.* 123, 3737–3765. <https://doi.org/10.1007/s00170-022-10403-z>
- Kumar, T.P., Reddy, P.P., 2018. Non-Destructive Analysis of FSW Process and Comparison With Simulation and Microstructural Analysis. *Procedia Manuf.* 20, 187–194. <https://doi.org/10.1016/j.promfg.2018.02.027>
- Kumpati, R., Skarka, W., Ontipuli, S.K., 2021. Current Trends in Integration of Nondestructive Testing Methods for Engineered Materials Testing. *Sensors* 21, 6175. <https://doi.org/10.3390/s21186175>
- Leider, R.A., 2015. *Robots: explore the world of robots and how they work for us*, Fact Atlas. Sky Pony Press, New York.
- Lensu, A., 2002. *Computationally Intelligent Methods for Qualitative Data Analysis*.
- Lezzi, M., Lazoi, M., Corallo, A., 2018. Cybersecurity for Industry 4.0 in the current literature: A reference framework. *Comput. Ind.* 103, 97–110. <https://doi.org/10.1016/j.compind.2018.09.004>
- Liu, M., Chen, D., Zhang, Q., Liu, Y., Zhao, Y., 2022. A Dynamic Multi-objective Evolutionary Algorithm Assisted by Kernel Ridge Regression, in: Xie, Q., Zhao, L., Li, K., Yadav, A., Wang, L. (Eds.), *Advances in Natural Computation, Fuzzy Systems and Knowledge Discovery, Lecture Notes on Data Engineering and Communications Technologies*. Springer International Publishing, Cham, pp. 128–136. https://doi.org/10.1007/978-3-030-89698-0_14
- Lokrantz, A., Gustavsson, E., Jirstrand, M., 2018. Root cause analysis of failures and quality deviations in manufacturing using machine learning. *Procedia CIRP* 72, 1057–1062. <https://doi.org/10.1016/j.procir.2018.03.229>
- Long, G.J., Lin, B.H., Cai, H.X., Nong, G.Z., 2020. Developing an Artificial Intelligence (AI) Management System to Improve Product Quality and Production Efficiency in Furniture Manufacture. *Procedia Comput. Sci.* 166, 486–490. <https://doi.org/10.1016/j.procs.2020.02.060>
- Luo, Q., Fang, X., Liu, L., Yang, C., Sun, Y., 2020. Automated Visual Defect Detection for Flat Steel Surface: A Survey. *IEEE Trans. Instrum. Meas.* 69, 626–644. <https://doi.org/10.1109/TIM.2019.2963555>
- Luo, Y., Zhu, L., Han, J., Xie, X., Wan, R., Zhu, Y., 2019. Study on the acoustic emission effect of plasma plume in pulsed laser welding. *Mech. Syst. Signal Process.* 124, 715–723. <https://doi.org/10.1016/j.ymssp.2019.01.045>
- Luo, Z., Liu, W., Wang, Z., Ao, S., 2016. Monitoring of laser welding using source localization and tracking processing by microphone array. *Int. J. Adv. Manuf. Technol.* 86, 21–28. <https://doi.org/10.1007/s00170-015-8095-x>
- Lv, N., Zhong, J., Chen, H., Lin, T., Chen, S., 2014. Real-time control of welding penetration during robotic GTAW dynamical process by audio sensing of arc length. *Int. J. Adv. Manuf. Technol.* 74, 235–249. <https://doi.org/10.1007/s00170-014-5875-7>
- Lv, X., Duan, F., Jiang, J.-J., Fu, X., Gan, L., 2020. Deep Active Learning for Surface Defect Detection. *Sensors* 20, 1650. <https://doi.org/10.3390/s20061650>
- Ma, L., Xie, W., Zhang, Y., 2019. Blister Defect Detection Based on Convolutional Neural Network for Polymer Lithium-Ion Battery. *Appl. Sci.* 9, 1085. <https://doi.org/10.3390/app9061085>
- Machado, M.A., Antin, K.-N., Rosado, L.S., Vilaça, P., Santos, T.G., 2021. High-speed inspection of delamination defects in unidirectional CFRP by non-contact eddy

- current testing. *Compos. Part B Eng.* 224, 109167.
<https://doi.org/10.1016/j.compositesb.2021.109167>
- Machado, M.A., Rosado, L.F.S.G., Mendes, N.A.M., Miranda, R.M.M., Dos Santos, T.J.G., 2022. New directions for inline inspection of automobile laser welds using non-destructive testing. *Int. J. Adv. Manuf. Technol.* 118, 1183–1195.
<https://doi.org/10.1007/s00170-021-08007-0>
- Madupu, P., Sk, A., Moses, E.M., Sreedhar, P., 2017. Non Destructive Testing For Multipass Gas Tungsten Arc Welding Process for Dissimilar Material 2.
- Maev, R.Gr., Chertov, A., Scott, R., Stocco, D., Ouellette, A., Denisov, A., Oberdorfer, Y., 2021. NDE in The Automotive Sector, in: Meyendorf, N., Ida, N., Singh, R., Vrana, J. (Eds.), *Handbook of Nondestructive Evaluation 4.0*. Springer International Publishing, Cham, pp. 1–32. https://doi.org/10.1007/978-3-030-48200-8_21-1
- Manikandan, K.R., Ashwin Sivagurunathan, P., Ananthan, S.S., Arul Marcel Moshi, A., Sundara Bharathi, S.R., 2021. Study on the influence of temperature and vibration on indications of liquid penetrant testing of A516 low carbon steel. *Mater. Today Proc.* 39, 1559–1564. <https://doi.org/10.1016/j.matpr.2020.05.572>
- Mao, S., Wang, B., Tang, Y., Qian, F., 2019. Opportunities and Challenges of Artificial Intelligence for Green Manufacturing in the Process Industry. *Engineering* 5, 995–1002. <https://doi.org/10.1016/j.eng.2019.08.013>
- Matzka, S., 2020. Explainable Artificial Intelligence for Predictive Maintenance Applications, in: 2020 Third International Conference on Artificial Intelligence for Industries (AI4I). Presented at the 2020 Third International Conference on Artificial Intelligence for Industries (AI4I), IEEE, Irvine, CA, USA, pp. 69–74.
<https://doi.org/10.1109/AI4I49448.2020.00023>
- Mealy, P., 2018. *Virtual & augmented reality for dummies*, 1st edition. ed. John Wiley and Sons, Indianapolis, IN.
- Meola, C., Squillace, A., Minutolo, F.M.C., Morace, R.E., 2004. Analysis of stainless steel welded joints: a comparison between destructive and non-destructive techniques. *J. Mater. Process. Technol.* 155–156, 1893–1899.
<https://doi.org/10.1016/j.jmatprotec.2004.04.303>
- Misokefalou, Dr.E., Papoutsidakis, Prof.M., University of West Attica, Priniotakis, Prof.G., University of West Attica, 2022. Non-destructive testing for quality control in automotive industry. *Int. J. Eng. Appl. Sci. Technol.* 7, 349–355.
<https://doi.org/10.33564/IJEAST.2022.v07i01.054>
- Mookam, N., 2019. Optimization of resistance spot brazing process parameters in AHSS and AISI 304 stainless steel joint using filler metal. *Def. Technol.* 15, 450–456.
<https://doi.org/10.1016/j.dt.2019.03.005>
- Mourtzis, D., Angelopoulos, J., Arvanitis, A.N., Panopoulos, N., 2022. Automating Quality Control Based on Machine Vision Towards Automotive 4.0, in: Kim, D.Y., von Cieminski, G., Romero, D. (Eds.), *Advances in Production Management Systems. Smart Manufacturing and Logistics Systems: Turning Ideas into Action*, IFIP Advances in Information and Communication Technology. Springer Nature Switzerland, Cham, pp. 126–134. https://doi.org/10.1007/978-3-031-16407-1_16
- Naranjo, J.E., Sanchez, D.G., Robalino-Lopez, A., Robalino-Lopez, P., Alarcon-Ortiz, A., Garcia, M.V., 2020. A Scoping Review on Virtual Reality-Based Industrial Training. *Appl. Sci.* 10, 8224. <https://doi.org/10.3390/app10228224>
- Nayyar, A., Kumar, A. (Eds.), 2020. *A Roadmap to Industry 4.0: Smart Production, Sharp Business and Sustainable Development*, *Advances in Science, Technology & Innovation*. Springer International Publishing, Cham. <https://doi.org/10.1007/978-3-030-14544-6>

- Nee, A.Y.C., Ong, S.K. (Eds.), 2023. Springer handbook of augmented reality. Springer, Cham.
- Onit, 2020. Five ways AI accelerates pre signature contract review [WWW Document]. URL <https://www.onit.com/blog/five-ways-ai-accelerates-pre-signature-contract-review/> (accessed 7.23.23).
- Ou, W., Xiao, S., Zhu, C., Han, W., Zhang, Q., 2022. An overview of brain-like computing: Architecture, applications, and future trends. *Front. Neurobotics* 16, 1041108. <https://doi.org/10.3389/fnbot.2022.1041108>
- Pajić, N., Djapan, M., Buluschek, E., Fahrenbruch, W., Đorđević, A., Stefanović, M., 2023a. Machine learning prediction model for small data sets instead of destructive tests for a case of resistance brazing process verification. *International Journal of Industrial Engineering: Theory, Applications and Practice*, 30(3). <https://doi.org/10.2305/IJIETAP.2023.30.3.8691>
- Pajić, N., Pavlović, L., Živić, F., Aleksić, J., 2023b. Enhancement of outdated vision systems in smes with artificial intelligence powered solutions. *Applied Artificial Intelligence 2: Medicine, Biology, Chemistry, Financial, Games, Engineering, The Second Serbian International Conference on Applied Artificial Intelligence (SICAAI)* 168-169 ISBN: 978-3-031-60840-7
- Pandian, Dr.A.P., 2019. Artificial intelligence application in smart warehousing environment for automated logistics. *J. Artif. Intell. Capsule Netw.* 2019, 63–72. <https://doi.org/10.36548/jaicn.2019.2.002>
- Parida, K., Bark, H., Lee, P.S., 2021. Emerging Thermal Technology Enabled Augmented Reality. *Adv. Funct. Mater.* 31, 2007952. <https://doi.org/10.1002/adfm.202007952>
- Pascual, D.G., Daponte, P., Kumar, U., 2020. *Handbook of Industry 4.0 and SMART Systems*. CRC Press/Taylor & Francis Group, Boca Raton.
- Pimenov, D.Y., Bustillo, A., Wojciechowski, S., Sharma, V.S., Gupta, M.K., Kuntoğlu, M., 2023. Artificial intelligence systems for tool condition monitoring in machining: analysis and critical review. *J. Intell. Manuf.* 34, 2079–2121. <https://doi.org/10.1007/s10845-022-01923-2>
- Pournader, M., Ghaderi, H., Hassanzadegan, A., Fahimnia, B., 2021. Artificial intelligence applications in supply chain management. *Int. J. Prod. Econ.* 241, 108250. <https://doi.org/10.1016/j.ijpe.2021.108250>
- Provencal, E., Laperrière, L., 2021. Identification of weld geometry from ultrasound scan data using deep learning. *Procedia CIRP* 104, 122–127. <https://doi.org/10.1016/j.procir.2021.11.021>
- Qi, C., Fourie, A., Zhao, X., 2018. Back-Analysis Method for Slope Displacements Using Gradient-Boosted Regression Tree and Firefly Algorithm. *J. Comput. Civ. Eng.* 32, 04018031. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000779](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000779)
- Redwood, B., Garrett, B., Schöffner, F., 2017. *The 3D printing handbook: technologies, design and applications*. 3D Hubs, Amsterdam.
- Regaard, B., Fiedler, W., Kaierle, S., 2007. Error detection in lap welding applications using on-line melt pool contour analysis by coaxial process monitoring with external illumination.
- Riahi, Y., Saikouk, T., Gunasekaran, A., Badraoui, I., 2021. Artificial intelligence applications in supply chain: A descriptive bibliometric analysis and future research directions. *Expert Syst. Appl.* 173, 114702. <https://doi.org/10.1016/j.eswa.2021.114702>
- Ribeiro, J., Lima, R., Eckhardt, T., Paiva, S., 2021. Robotic Process Automation and Artificial Intelligence in Industry 4.0 – A Literature review. *Procedia Comput. Sci.* 181, 51–58. <https://doi.org/10.1016/j.procs.2021.01.104>

- Robins, M., 2020. Difference between AI machine learning and deep learning.
- Rodriguez-Galiano, V., Sanchez-Castillo, M., Chica-Olmo, M., Chica-Rivas, M., 2015. Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines. *Ore Geol. Rev.* 71, 804–818. <https://doi.org/10.1016/j.oregeorev.2015.01.001>
- Rohrer, B., 2021. How Deep Neural Networks Work.
- Rong, Y., Zhang, G., Chang, Y., Huang, Y., 2016. Integrated optimization model of laser brazing by extreme learning machine and genetic algorithm. *Int. J. Adv. Manuf. Technol.* 87, 2943–2950. <https://doi.org/10.1007/s00170-016-8649-6>
- Salhaoui, M., Guerrero-González, A., Arioua, M., Ortiz, F.J., El Oualkadi, A., Torregrosa, C.L., 2019. Smart Industrial IoT Monitoring and Control System Based on UAV and Cloud Computing Applied to a Concrete Plant. *Sensors* 19, 3316. <https://doi.org/10.3390/s19153316>
- Sankar, K., Jackovich, J., Richards, R., 2020. The applied AI and natural language processing workshop. Packt Publishing, Birmingham, UK.
- Sassi, P., Tripicchio, P., Avizzano, C.A., 2019. A Smart Monitoring System for Automatic Welding Defect Detection. *IEEE Trans. Ind. Electron.* 66, 9641–9650. <https://doi.org/10.1109/TIE.2019.2896165>
- Schaefer, T.B., 2019. The Ethical Implications of Artificial Intelligence in the Law. *Gonz Rev* 55, 221.
- Sehwi MARCOS Lee, 2018. The Importance of Engineering Outsourcing in the Automotive Industry and the Future Prospects of Korean Suppliers. <https://doi.org/10.13140/RG.2.2.24065.71524>
- Sendek, A.D., Ransom, B., Cubuk, E.D., Pellouchoud, L.A., Nanda, J., Reed, E.J., 2022. Machine Learning Modeling for Accelerated Battery Materials Design in the Small Data Regime. *Adv. Energy Mater.* 12, 2200553. <https://doi.org/10.1002/aenm.202200553>
- Sevryukov, O.N., Suchkov, A.N., National Research Nuclear University MEPhI (Moscow Engineering Physics Institute), Moscow, Russia, Guseva, E.V., National Research Nuclear University MEPhI (Moscow Engineering Physics Institute), Moscow, Russia, 2015. Brazing of modern engineering materials with STEMET amorphous brazing filler metals. *Non-Ferr. Met.* 45–49. <https://doi.org/10.17580/nfm.2015.01.12>
- Shadbolt, N., Berners-Lee, T., 2008. Web Science Emerges. *Sci. Am.* 299, 76–81. <https://doi.org/10.1038/scientificamerican1008-76>
- Shahrubudin, N., Lee, T.C., Ramlan, R., 2019. An Overview on 3D Printing Technology: Technological, Materials, and Applications. *Procedia Manuf.* 35, 1286–1296. <https://doi.org/10.1016/j.promfg.2019.06.089>
- Sharma, A., 2023. Making electric vehicle batteries safer through better inspection using artificial intelligence and cobots. *Int. J. Prod. Res.* 1–20. <https://doi.org/10.1080/00207543.2023.2180308>
- Sherwani, F., Asad, M.M., Ibrahim, B.S.K.K., 2020. Collaborative Robots and Industrial Revolution 4.0 (IR 4.0), in: 2020 International Conference on Emerging Trends in Smart Technologies (ICETST). Presented at the 2020 International Conference on Emerging Trends in Smart Technologies (ICETST), IEEE, Karachi, Pakistan, pp. 1–5. <https://doi.org/10.1109/ICETST49965.2020.9080724>
- Shevchik, S., Le-Quang, T., Meylan, B., Farahani, F.V., Olbinado, M.P., Rack, A., Masinelli, G., Leinenbach, C., Wasmer, K., 2020. Supervised deep learning for real-time quality monitoring of laser welding with X-ray radiographic guidance. *Sci. Rep.* 10, 3389. <https://doi.org/10.1038/s41598-020-60294-x>

- Shevchik, S.A., Le-Quang, T., Farahani, F.V., Faivre, N., Meylan, B., Zanoli, S., Wasmer, K., 2019. Laser Welding Quality Monitoring via Graph Support Vector Machine With Data Adaptive Kernel. *IEEE Access* 7, 93108–93122. <https://doi.org/10.1109/ACCESS.2019.2927661>
- Shrestha, Y.R., Ben-Menahem, S.M., Von Krogh, G., 2019. Organizational Decision-Making Structures in the Age of Artificial Intelligence. *Calif. Manage. Rev.* 61, 66–83. <https://doi.org/10.1177/0008125619862257>
- Shukla, A.K., Janmajaya, M., Abraham, A., Muhuri, P.K., 2019. Engineering applications of artificial intelligence: A bibliometric analysis of 30 years (1988–2018). *Eng. Appl. Artif. Intell.* 85, 517–532. <https://doi.org/10.1016/j.engappai.2019.06.010>
- Shwartz-Ziv, R., Armon, A., 2021. Tabular Data: Deep Learning is Not All You Need.
- Siegel, J.E., Beemer, M.F., Shepard, S.M., 2020. Automated non-destructive inspection of Fused Filament Fabrication components using Thermographic Signal Reconstruction. *Addit. Manuf.* 31, 100923. <https://doi.org/10.1016/j.addma.2019.100923>
- Singh, R., 2020. Magnetic particle testing, in: *Applied Welding Engineering*. Elsevier, pp. 331–338. <https://doi.org/10.1016/B978-0-12-821348-3.00024-0>
- Siwiec, D., Pacana, A., 2021. Method of improve the level of product quality. *Prod. Eng. Arch.* 27, 1–7. <https://doi.org/10.30657/pea.2021.27.1>
- Sparck Jones, K., Galliers, J.R., 1995. Evaluating natural language processing systems: an analysis and review, *Lecture notes in computer science; Lecture notes in artificial intelligence*. Springer, Berlin ; New York.
- Strehl, A.L., Littman, M.L., 2007. *Online Linear Regression and Its Application to Model-Based Reinforcement Learning*.
- Stulp, F., Sigaud, O., 2015. Many regression algorithms, one unified model: A review. *Neural Netw.* 69, 60–79. <https://doi.org/10.1016/j.neunet.2015.05.005>
- Sumesh, A., Rameshkumar, K., Mohandas, K., Babu, R.S., 2015. Use of Machine Learning Algorithms for Weld Quality Monitoring using Acoustic Signature. *Procedia Comput. Sci.* 50, 316–322. <https://doi.org/10.1016/j.procs.2015.04.042>
- Šušteršič, T., Milovanović, V., Ranković, V., Filipović, N., 2020. A comparison of classifiers in biomedical signal processing as a decision support system in disc hernia diagnosis. *Comput. Biol. Med.* 125, 103978. <https://doi.org/10.1016/j.compbimed.2020.103978>
- Talin, A.A., n.d. *Ion Insertion Electrodes for Brain Inspired Computing*.
- Ťavodová, M., Náprstková, N., Hnilicová, M., Beňo, P., 2020. Quality evaluation of welding joints by different methods. *FME Trans.* 48, 816–824. <https://doi.org/10.5937/fme2004816T>
- Tenner, F., Berg, B., Brock, C., Klämpfl, F., Schmidt, M., 2015. Experimental approach for quantification of fluid dynamics in laser metal welding. *J. Laser Appl.* 27, S29003. <https://doi.org/10.2351/1.4906302>
- Terven, J., Cordova-Esparza, D., 2023. A Comprehensive Review of YOLO: From YOLOv1 and Beyond. <https://doi.org/10.48550/ARXIV.2304.00501>
- Terziyan, V., Vitko, O., 2023. Causality-Aware Convolutional Neural Networks for Advanced Image Classification and Generation. *Procedia Comput. Sci.* 217, 495–506. <https://doi.org/10.1016/j.procs.2022.12.245>
- Todolí-Signes, A., 2021. Making algorithms safe for workers: occupational risks associated with work managed by artificial intelligence. *Transf. Eur. Rev. Labour Res.* 27, 433–452. <https://doi.org/10.1177/10242589211035040>
- Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P., Fischl, M., 2021. Artificial intelligence in supply chain management: A systematic literature review. *J. Bus. Res.* 122, 502–517. <https://doi.org/10.1016/j.jbusres.2020.09.009>

- Tsukamoto, S., 2003. Laser Welding. *Weld. Int.* 17, 767–774.
<https://doi.org/10.1533/wint.2003.3172>
- Ustundag, A., Cevikcan, E., 2018. *Industry 4.0: Managing The Digital Transformation*, Springer Series in Advanced Manufacturing. Springer International Publishing, Cham. <https://doi.org/10.1007/978-3-319-57870-5>
- Vänskä, M., Abt, F., Weber, R., Salminen, A., Graf, T., 2013. Effects of Welding Parameters Onto Keyhole Geometry for Partial Penetration Laser Welding. *Phys. Procedia* 41, 199–208. <https://doi.org/10.1016/j.phpro.2013.03.070>
- Vasilev, M., MacLeod, C., Galbraith, W., Javadi, Y., Foster, E., Dobie, G., Pierce, G., Gachagan, A., 2021. Non-contact in-process ultrasonic screening of thin fusion welded joints. *J. Manuf. Process.* 64, 445–454.
<https://doi.org/10.1016/j.jmapro.2021.01.033>
- Vishal, V., Ramya, R., Vinay Srinivas, P., Vimal Samsingh, R., 2019. A review of implementation of Artificial Intelligence systems for weld defect classification. *Mater. Today Proc.* 16, 579–583. <https://doi.org/10.1016/j.matpr.2019.05.131>
- Volpp, J., 2017. Keyhole stability during laser welding—Part II: process pores and spatters. *Prod. Eng.* 11, 9–18. <https://doi.org/10.1007/s11740-016-0705-4>
- Vrontis, D., Christofi, M., Pereira, V., Tarba, S., Makrides, A., Trichina, E., 2022. Artificial intelligence, robotics, advanced technologies and human resource management: a systematic review. *Int. J. Hum. Resour. Manag.* 33, 1237–1266.
<https://doi.org/10.1080/09585192.2020.1871398>
- Vu, K., Snyder, J., Li, L., Rupp, M., Chen, B.F., Khelif, T., Müller, K.-R., Burke, K., 2015. Understanding Kernel Ridge Regression: Common behaviors from simple functions to density functionals.
- Wang, B., Hu, S.J., Sun, L., Freiheit, T., 2020. Intelligent welding system technologies: State-of-the-art review and perspectives. *J. Manuf. Syst.* 56, 373–391.
<https://doi.org/10.1016/j.jmsy.2020.06.020>
- Wang, J., Fu, P., Gao, R.X., 2019. Machine vision intelligence for product defect inspection based on deep learning and Hough transform. *J. Manuf. Syst.* 51, 52–60.
<https://doi.org/10.1016/j.jmsy.2019.03.002>
- Wang, W., Siau, K., 2019. Artificial Intelligence, Machine Learning, Automation, Robotics, Future of Work and Future of Humanity: A Review and Research Agenda. *J. Database Manag.* 30, 61–79. <https://doi.org/10.4018/JDM.2019010104>
- Wankerl, H., Stern, M.L., Altieri-Weimar, P., Al-Baddai, S., Lang, K.-J., Roider, F., Lang, E.W., 2020. Fully convolutional networks for void segmentation in X-ray images of solder joints. *J. Manuf. Process.* 57, 762–767.
<https://doi.org/10.1016/j.jmapro.2020.07.021>
- Weberpals, J., Hermann, T., Berger, P., Singpiel, H., 2011. Utilisation of Thermal Radiation for Process Monitoring. *Phys. Procedia* 12, 704–711.
<https://doi.org/10.1016/j.phpro.2011.03.088>
- Weis, S., Fedorov, V., Elssner, M., Uhlig, T., Hausner, S., Wagner, G., Wielage, B., 2017. Research trends in brazing and soldering. *Przegląd Spaw. - Weld. Technol. Rev.* 89. <https://doi.org/10.26628/ps.v89i7.797>
- Woschank, M., Rauch, E., Zsifkovits, H., 2020. A Review of Further Directions for Artificial Intelligence, Machine Learning, and Deep Learning in Smart Logistics. *Sustainability* 12, 3760. <https://doi.org/10.3390/su12093760>
- Wu, D., Chen, H., He, Y., Song, S., Lin, T., Chen, S., 2016. A prediction model for keyhole geometry and acoustic signatures during variable polarity plasma arc welding based on extreme learning machine. *Sens. Rev.* 36, 257–266. <https://doi.org/10.1108/SR-01-2016-0009>

- Wu, S.C., Yu, C., Zhang, W.H., Fu, Y.N., Helfen, L., 2015. Porosity induced fatigue damage of laser welded 7075-T6 joints investigated via synchrotron X-ray microtomography. *Sci. Technol. Weld. Join.* 20, 11–19. <https://doi.org/10.1179/1362171814Y.0000000249>
- Xia, T.K., Hui, P.M., Stroud, D., 1990. Theory of Faraday rotation in granular magnetic materials. *J. Appl. Phys.* 67, 2736–2741. <https://doi.org/10.1063/1.345438>
- Xiao, Z., Song, K.-Y., Gupta, M.M., 2021. Development of a CNN edge detection model of noised X-ray images for enhanced performance of non-destructive testing. *Measurement* 174, 109012. <https://doi.org/10.1016/j.measurement.2021.109012>
- Yan, J., Gao, M., Zeng, X., 2010. Study on microstructure and mechanical properties of 304 stainless steel joints by TIG, laser and laser-TIG hybrid welding. *Opt. Lasers Eng.* 48, 512–517. <https://doi.org/10.1016/j.optlaseng.2009.08.009>
- Yonebayashi, H., Kobayashi, A., Hirano, S., Okawara, M., Iwata, T., 2021. Boosting HSE Management More Efficiently and Sustainably: How Innovation Can Bring Change in Traditional HSE Mindsets?, in: Day 2 Tue, November 16, 2021. Presented at the Abu Dhabi International Petroleum Exhibition & Conference, SPE, Abu Dhabi, UAE, p. D021S028R001. <https://doi.org/10.2118/208177-MS>
- Yu, L., Qin, S., Zhang, M., Shen, C., Jiang, T., Guan, X., 2021. A Review of Deep Reinforcement Learning for Smart Building Energy Management. *IEEE Internet Things J.* 8, 12046–12063. <https://doi.org/10.1109/JIOT.2021.3078462>
- Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., Liu, C., 2014. Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review. *Food Res. Int.* 62, 326–343. <https://doi.org/10.1016/j.foodres.2014.03.012>
- Zhang, Y., Ling, C., 2018. A strategy to apply machine learning to small datasets in materials science. *Npj Comput. Mater.* 4, 25. <https://doi.org/10.1038/s41524-018-0081-z>
- Zhang, Y., Liu, H., Zhang, Z., Luo, Y., Guo, Q., Liao, S., 2020. Cloud computing-based real-time global optimization of battery aging and energy consumption for plug-in hybrid electric vehicles. *J. Power Sources* 479, 229069. <https://doi.org/10.1016/j.jpowsour.2020.229069>
- Zhao, L., Dai, T., Qiao, Z., Sun, P., Hao, J., Yang, Y., 2020. Application of artificial intelligence to wastewater treatment: A bibliometric analysis and systematic review of technology, economy, management, and wastewater reuse. *Process Saf. Environ. Prot.* 133, 169–182. <https://doi.org/10.1016/j.psep.2019.11.014>
- Zhou, T., Xu, R., Ruan, B., He, Y., Liang, Z., Wang, X., 2020. Study on new method and mechanism of microcutting-etching of microlens array on 6H-SiC mold by combining single point diamond turning with ion beam etching. *J. Mater. Process. Technol.* 278, 116510. <https://doi.org/10.1016/j.jmatprotec.2019.116510>
- Zolfaghari, Abolfazl, Zolfaghari, Amin, Kolahan, F., 2018. Reliability and sensitivity of magnetic particle nondestructive testing in detecting the surface cracks of welded components. *Nondestruct. Test. Eval.* 33, 290–300. <https://doi.org/10.1080/10589759.2018.1428322>
- Zonta, T., Da Costa, C.A., Da Rosa Righi, R., De Lima, M.J., Da Trindade, E.S., Li, G.P., 2020. Predictive maintenance in the Industry 4.0: A systematic literature review. *Comput. Ind. Eng.* 150, 106889. <https://doi.org/10.1016/j.cie.2020.106889>

Прилог

Код 4.2.4.1-1 Исецање слика и конверзија у .png

```
from PIL import Image
import os

# Подеси директоријум који садржи слике
image_dir = "C:\\Users\\images"

# Подеси директоријум за чување изрезаних слика
cropped_dir = "C:\\Users\\images_cropped"

# Креирај директоријум ако не постоји
if not os.path.exists(cropped_dir):
    os.makedirs(cropped_dir)

# Подеси координате за изрезивање
box = (0, 0, 1020, 760) # лево, горе, десно, доње

# Итерација кроз сваку слику у директоријуму
for filename in os.listdir(image_dir):

    # Провери да ли је датотека подржана слика
    if filename.endswith(".bmp"):

        # Отвори датотеку слике
        img = Image.open(os.path.join(image_dir, filename))

        # Исеци слику
        cropped_image = img.crop(box)

        # Конвертуј слику у PNG формат
        cropped_image = cropped_image.convert("RGB")

        # Сачувај изрезану слику у датотеку у изрезаном директоријуму
        cropped_filename = "cropped_" + filename.replace(".bmp", ".png")
        cropped_image_path = os.path.join(cropped_dir, cropped_filename)
        cropped_image.save(cropped_image_path)
```

Код 4.2.4.1-2 Побољшање слика и примена прага вредности („thresholding“)

```
# Адаптивни Отсуов праг
import cv2
import os
import numpy as np
# Одреди фолдер који садржи слике
image_dir = "C:\\Users\\images_cropped"

# Одреди фолдер за чување процесуираних слика
processed_dir = "C:\\Users\\images_cropped_processed"
if not os.path.exists(processed_dir):
    os.makedirs(processed_dir)

# Петља око сваке слике у директоријуму
for filename in os.listdir(image_dir):
    # Провери да ли је екстензија фајла подржана
    if filename.endswith(".jpg") or filename.endswith(".png"):
        # Учитај слику као црно-белу
        img = cv2.imread(os.path.join(image_dir, filename),
cv2.IMREAD_GRAYSCALE)

        # Одштампaj атрибуте фајла
        print(f"Filename: {filename}")
        print(f"File format: {filename.split('.')[-1]}")
        print(f"Image shape: {img.shape}")

        # Провери да ли је слика црно-бела
        if len(img.shape) == 2:
            print(f"{filename} is a grayscale image")
        else:
            print(f"{filename} is a color image")

        # Подеси контраст слике
        contrast_factor = 1.5
        img = cv2.convertScaleAbs(img, alpha=contrast_factor, beta=0)

        # Подеси осветљеност слике
        brightness_factor = 1.2
        img = cv2.convertScaleAbs(img, alpha=1, beta=brightness_factor)

        # Примени адаптивни праг
        adaptive_thresh_img = cv2.adaptiveThreshold(img, 255,
cv2.ADAPTIVE_THRESH_MEAN_C, cv2.THRESH_BINARY, 11, 2)

        # Примени Отсуов праг
        _, otsu_thresh_img = cv2.threshold(img, 0, 255, cv2.THRESH_BINARY +
cv2.THRESH_OTSU)
```

```

# Сачувај слике у дефинисани фолдер
processed_filename = "processed_" + filename
adaptive_thresh_image_path = os.path.join(processed_dir,
"adaptive_thresh_" + processed_filename)
cv2.imwrite(adaptive_thresh_image_path, adaptive_thresh_img)
otsu_thresh_image_path = os.path.join(processed_dir, "otsu_thresh_"
+ processed_filename)
cv2.imwrite(otsu_thresh_image_path, otsu_thresh_img)

```

Код 4.2.4.1-3 Увожење библиотека неопходних за тренирање модела

```

# Увожење неопходних билиотека
import tensorflow as tf
print("Num GPUs Available: ", len(tf.config.list_physical_devices('GPU')))
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dropout
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.callbacks import EarlyStopping, TensorBoard,
ModelCheckpoint

import os
import numpy as np
import matplotlib.pyplot as plt
from tqdm import tqdm
import pandas as pd
from tensorflow.keras.layers import Dense, Conv2D, MaxPooling2D, Dropout,
Flatten
from tensorflow.keras.applications import MobileNetV2
from tensorflow.keras.layers import Dense, Dropout, GlobalAveragePooling2D
from tensorflow.keras.layers import BatchNormalization
from tensorflow.keras.layers import GlobalAveragePooling2D, Dense
from tensorflow.keras.applications import VGG16
from tensorflow.keras.layers import GlobalAveragePooling2D, Dropout, Dense,
InputLayer, Flatten, Conv2D
from tensorflow.keras.callbacks import ModelCheckpoint
from sklearn.metrics import classification_report, confusion_matrix
import seaborn as sns
import datetime

```

Код 4.2.4.1-4 Дефинисање локација фолдера

```

# Дефинисање локација директоријума
train_path = "C:\\Users\\1000_images\\Training\\train"
validation_path = "C:\\Users\\1000_images\\Training\\validation"
test_path = "C:\\Users\\1000_images\\Training\\test"
log_dir = "C:\\Users\\1000_images\\Training\\logs"
best_model_path = "C:\\Users\\1000_images\\Training\\Model_saving"
base_model_path =
"C:\\Users\\1000_images\\Training\\Model_saving\\base_model.h5"

```

Код 4.2.4.1-5 Дефинисање временског печата за именовање сачуваног модела и чување тренираног модела

```
# Дефиниши време и датум за чување модела и назив фајла
def add_timestamp_to_filename(filename):
    current_datetime = datetime.datetime.now()
    timestamp = current_datetime.strftime("%Y%m%d_%H%M%S")
    base_name, extension = filename.rsplit(".", 1)
    timestamped_filename = f"{base_name}_{timestamp}.{extension}"
    return timestamped_filename

# Сачувај модел
save_path = "C:\\Users\\1000_images\\Training\\Model_saving\\"
filename = "my_model.h5"
timestamped_filename = add_timestamp_to_filename(filename)
model_save_path = save_path + timestamped_filename
```

Код 4.2.4.1-6 Учитавање претренираног модела

```
# Учитај претренирани модел VGG16
base_model = VGG16(input_shape=(img_height, img_width, 3),
                   include_top=False,
                   weights='imagenet')

# Замрзни базне слојеве модела
for layer in base_model.layers:
    layer.trainable = False

# Додај нову класификациону главу на врх базног модела
model = Sequential([
    Conv2D(3, (3, 3), padding='same'),
    base_model,
    Flatten(),
    Dense(64, activation='relu'),
    Dense(32, activation='relu'),
    Dense(1, activation='sigmoid')
])

# Компајлуј модел
model.compile(optimizer='adam', loss='binary_crossentropy',
             metrics=['accuracy'])
```

Код 4.2.4.1-7 Дефинисање генератора података

```
# Дефиниши генераторе података
augmentation_parameters = {
    'rotation_range': 10,
    'width_shift_range': 0.1,
    'height_shift_range': 0.1,
    'shear_range': 0.1,
    'zoom_range': 0.1,
    'horizontal_flip': True
}
#Дефиниши величину „беча“ и димензије слике
batch_size = 16
img_height = 450
img_width = 940

# Направи ImageDataGenerator са параметрима аугментације
datagen = ImageDataGenerator(rescale=1./255, **augmentation_parameters)
test_datagen = ImageDataGenerator(rescale=1./255)

# Дефиниши генераторе података за тренинг, валидацију, и тест скупове
train_generator = test_datagen.flow_from_directory(
    train_path,
    target_size=(img_height, img_width),
    batch_size=batch_size,
    color_mode='grayscale',
    class_mode='binary',
    classes=['0', '1']
)
validation_generator = test_datagen.flow_from_directory(
    validation_path,
    target_size=(img_height, img_width),
    color_mode='grayscale',
    batch_size=batch_size,
    class_mode='binary',
    classes=['0', '1']
)
test_generator = test_datagen.flow_from_directory(
    test_path,
    target_size=(img_height, img_width),
    batch_size=49,
    color_mode='grayscale',
    class_mode='binary',
    classes=['0', '1']
)
tensorboard_callback = tf.keras.callbacks.TensorBoard(log_dir=log_dir)

# Подеси ModelCheckpoint callback
checkpoint_callback = ModelCheckpoint(
```

```

    best_model_path,
    monitor='val_accuracy',
    mode='max',
    save_best_only=True,
    verbose=1,
    save_freq='epoch'
)

```

Код 4.2.4.1-8 Тренирање и чување модела

```

# Тренирај модел користећи TensorBoard и ModelCheckpoint callbacks
history = model.fit(train_generator, epochs=10,
validation_data=validation_generator, callbacks=[checkpoint_callback,
tensorboard_callback])

# Сачувај модел
tf.saved_model.save(model, model_save_path)

# Евалуирај најбољи модел на тест скупу података
test_loss, test_acc = model.evaluate(test_generator, verbose=2)
print('Test accuracy of the best model:', test_acc)

```

Код 4.2.4.2-1 Евалуација модела

```

test_path = "C:\\Users\\1000_images\\Training\\Trening\\test"
save_path = "C:\\Users\\1000_images\\Training\\Model_saving\\my_model7.h5"
model = tf.keras.models.load_model(save_path)

for index in os.listdir(test_path):
    for ID in os.listdir(os.path.join(test_path, index)):
        img = cv2.imread(test_path + index + "/" + ID, 0)
        img_array = np.asarray(img)/255
        img_array = np.expand_dims(img_array, axis=2)
        img_array = np.expand_dims(img_array, axis=0)
        prediction = model.predict(img_array)
        print("ID: " + ID + " / Label: " + index + " / Prediction: " +
str(prediction))

```


Код 4.2.5.1-1 Конверзија слика у одговарајућу екстензију

```
from PIL import Image
import os

def convert_bmp_to_jpg(directory):
    for root, _, files in os.walk(directory):
        for filename in files:
            if filename.lower().endswith(".bmp"):
                bmp_path = os.path.join(root, filename)
                jpg_path = os.path.splitext(bmp_path)[0] + ".jpg"

                try:
                    with Image.open(bmp_path) as img:
                        img.save(jpg_path, "JPEG")

                    os.remove(bmp_path) # Remove the original BMP file

                    print(f"Converted '{bmp_path}' to '{jpg_path}'")
                except Exception as e:
                    print(f"Failed to convert '{bmp_path}': {e}")

# Конвертуј BMP фајлове у JPG у директоријуму train/images
convert_bmp_to_jpg("C:/Nemanja/YOLO_adaptation/train/images")

# Конвертуј BMP фајлове у JPG у директоријуму valid/images
convert_bmp_to_jpg("C:/Nemanja/YOLO_adaptation/valid/images")

# Конвертуј BMP фајлове у JPG у директоријуму test/images
convert_bmp_to_jpg("C:/Nemanja/YOLO_adaptation/test/images")
```

Код 4.2.5.1-2 Опсецање непотребних делова слика

```
from PIL import Image
import os

def crop_images(folder_path, crop_coordinates):
    # Направи нови фолдер за исечене слике
    cropped_folder = os.path.join(folder_path, "cropped_images")
    os.makedirs(cropped_folder, exist_ok=True)

    for filename in os.listdir(folder_path):
        if filename.endswith(".jpg") or filename.endswith(".bmp"):
            # Отвори слику
            image_path = os.path.join(folder_path, filename)
            image = Image.open(image_path)

            # Исеци слику
            cropped_image = image.crop(crop_coordinates)

            # Сачувај исечену слику
            cropped_image.save(os.path.join(cropped_folder, filename))
            print(f"Cropped image: {filename}")

# Дефиниши фолдер у ком се налазе слике
folder_path = r"C:\YOLO_CROPED\train\images"
crop_coordinates = (0, 0, 1020, 760)
```

```
crop_images(folder_path, crop_coordinates)
```

Код 4.2.5.1-3 Промена формата слика за обуку модела

```
from PIL import Image
import os

def resize_images(folder_path):
    # Направи нови фолдер за слике са промењеним димензијама
    resized_folder = os.path.join(folder_path, "resized_images")
    os.makedirs(resized_folder, exist_ok=True)

    for filename in os.listdir(folder_path):
        if filename.endswith(".jpg") or filename.endswith(".bmp") or
filename.endswith(".png"):
            # Отвори слику
            image_path = os.path.join(folder_path, filename)
            image = Image.open(image_path)

            # Прмени слику и задржи формат
            image.thumbnail((640, 640))

            # Сачувај измењену слику
            resized_image_path = os.path.join(resized_folder, filename)
            image.save(resized_image_path, quality=98)

            print(f"Resized image: {filename}")

# Дефиниши фолдер у ком се налазе слике
folder_path = r'C:\YOLO_CROPED\train\images'
resize_images(folder_path)
```

Код 4.2.5.1-4 Побољшање графичких параметара слика у скупу за тренинг

```
import cv2
import os

# Дефиниши фолдер у ком се налазе слике
image_dir = r"C:\YOLO_CROPED\train\images"

# Направи петљу око сваке слике у директоријуму
for filename in os.listdir(image_dir):
    # Провери да ли је екстензија фајла подржана
    if filename.endswith(".jpg") or filename.endswith(".png"):
        # Учитај црно-белу слику
        img = cv2.imread(os.path.join(image_dir, filename),
cv2.IMREAD_GRAYSCALE)

        # Одштампај атрибуте фајла
        print(f"Filename: {filename}")
        print(f"File format: {filename.split('.')[-1]}")
        print(f"Image shape: {img.shape}")

        # Провери да ли је слика црно-бела
        if len(img.shape) == 2:
            print(f"{filename} is a grayscale image")
```

```

else:
    print(f"{filename} is a color image")

# Подеси контраст
contrast_factor = 1.5
img = cv2.convertScaleAbs(img, alpha=contrast_factor, beta=0)

# Подеси осветљеност
brightness_factor = 1.2
img = cv2.convertScaleAbs(img, alpha=1, beta=brightness_factor)

# Сачувај слику (замени постојећу новом)
cv2.imwrite(os.path.join(image_dir, filename), img)

```

Код 4.2.5.2-1 Побољшање графичких параметара слика у скупу за тренинг

```

from ultralytics import YOLO

# Учитај модел
model = YOLO("yolov8s.pt")

# Покрени модел
model.train(data="C:\\Nemanja\\YOLO_relabeled\\dataset.yaml", epochs=10) #
Обучи модел
metrics = model.val() # Евалуирај перформансе на валидационом сету
results = model("C:\\Nemanja\\YOLOv8\\Images\\Test\\NOK\\Image3430.bmp") #
Изврши предвиђање за дату слику
path = model.export(format="onnx") # експортуј модел

```

Код 4.2.5.2-2 Дефинисање путања фолдера и класа објеката

```

#path: ../datasets/coco128 # dataset root dir
train: C:\\YOLO_relabeled\\train
val: C:\\YOLO_relabeled\\valid
test: C:\\YOLO_relabeled\\test

# Classes
nc: 9 # number of classes
names: ['OK': 0,
        'Glue filling level NOK': 1,
        'Missing glue': 2,
        'Glue overflow': 3,
        'Air bubble': 4,
        'Damage': 5,
        'Contamination': 6,
        'Improper position': 7,
        'Missing piece': 8] # class names

```

Код 4.2.5.2-3 Оптимизација параметара за обучавање модела

```
# Дефиниши специфичне параметре за тренинг модела
trainer_params = {
    'epochs': 80,
    'batch': 1,
    'imgsz': 1280,
    'workers': 4,
    'lr0': 0.01,
    'lrf': 0.002,
    'momentum': 0.937,
    'weight_decay': 0.0005,
    'warmup_epochs': 3.0,
    'warmup_momentum': 0.8,
    'warmup_bias_lr': 0.1,
    'box': 7.9,
    'cls': 0.6,
    'dfl': 1.5,
    'pose': 12.0,
    'kobj': 1.0,
    'label_smoothing': 0.1,
    'nbs': 64,
    'hsv_h': 0.015,
    'hsv_s': 0.7,
    'hsv_v': 0.4,
    'degrees': 0.0,
    'translate': 0.1,
    'scale': 0.1,
    'shear': 0.0,
    'perspective': 0.0,
    'flipud': 0.3,
    'fliplr': 0.3,
    'mosaic': 0.0,
    'mixup': 0.0,
    'copy_paste': 0.25
}
```

Код 4.2.5.3-1 Оптимизација параметара за обучавање модела

```
from ultralytics import YOLO
import cv2

# Тестирај модел
model =
YOLO("C:\\\\Nemanja\\\\YOLO_relabeled\\\\runs\\\\detect\\\\train8\\\\weights\\\\best.pt")

# Користи модел да изврши предвиђање за одређени скуп слика и сачувај
резултате
model.predict()
img=cv2.imread("C:\\\\Nemanja\\\\YOLO_relabeled\\\\test\\\\images\\\\")
res=model(img)
res_plotted=res[0].plot()
cv2.imwrite("C:\\\\Nemanja\\\\YOLO_relabeled\\\\runs\\\\detect\\\\test\\\\image_predict
ion.jpg", res_plotted)
```

БИОГРАФИЈА СА РЕФЕРЕНЦАМА

Лични подаци

Име и презиме: Немања Пајић

Датум и место рођења: 20.12.1990 Баточина

Адреса: Александра Симића 13, 34227 Баточина

Е-mail: pajicnemanja2@gmail.com

Немања Пајић рођен је 20. децембра 1990. године у Крагујевцу. Завршио је основну школу, од првог до осмог разреда, "Свети Сава" у Баточини, а након тога "Пољопривредно-ветеринарску школу са домом ученика - Свилајнац" у Свилајнцу, смер ветеринарски техничар-огледно одељење.

Школске 2014/2015. године уписао је основне студије на Универзитету Унион Никола Тесла Београд – Факултету за менаџмент – Сремски Карловци, смер Инжењерски менаџмент. Основне студије завршио је 2019. године са просечном оценом 8.61. Завршни рад одбранио је са оценом 10.

Школске 2019/2020. године уписује мастер академске студије на студијском програму Инжењерски менаџмент на Факултету инжењерских наука у Крагујевцу, и дипломира 2020. године са просечном оценом 9.57. Мастер рад одбранио је са оценом 10. Добио је награду факултета као најбољи свршени студент за школску 2019/2020. годину на образовном модулу Инжењерски менаџмент.

Докторске академске студије (ДАС) уписао је школске 2020/2021. године на студијском програму Машинско инжењерство: Индустријски инжењеринг. Током прве две године ДАС успешно је положио све испите предвиђене наставним планом и програмом са просечном оценом 10. У склопу реализованих активности прикупљена је литература и реализовани су експерименти из области теме докторске дисертације, на основу којих су публиковани радови.

Досадашњи научно-истраживачки рад и интересовања тежишно су усмерена на примену нових технологија у индустријском окружењу.

Има 15 година радног искуства у неким од највећих производних компанија у Србији, претежно из аутомобилске индустрије. Радио је на инжењерским, експертским и менаџерским позицијама у квалитету, дигитализацији, и високо технолошким департманима у компанијама: Fiat Automobili Srbija, Hutchinson, ZF Group, GiR, Moretto Spa., Minela d.o.o.. Радио је као асистент код проф. Владана Петровића на пословима усменог и писаног превођења, припреме документације и материјала за презентовање технологија из области алтернативних извора енергије. Бави се имплементацијом нових технологија у производној индустрији зарад унапређења процеса управљања квалитетом. Велик фокус му је на примени вештачке интелигенције у домену контроле квалитета, и недеструктивним методама тестирања. Развио је више апликација заснованих на вештачкој интелигенцији за класификацију слика, препознавање облика, обраду процесних параметара, као и генеративне трансформаторе текста (chat bot). Говори енглески језик. Познаје Agile и Scrum методологију рада. Поседује низ сертификата из области квалитета као и стручна знања о алатима, стандардима, и методологијама попут: *Lean Six Sigma*, VDA 6.3, IATF 16949, MSA, PPAP, 8D, SPC, управљање пројектима, интерна ревизија процеса и производа, итд... Познаје основе програмирања (Python, C, C++, C#, XHTML, CSS, Java, KNIME...). Мастерирао је на теми примене 3Д штампе у визуелној комуникацији, и познаје рад у Solid Worksu. Бавио се применом микро и нано технологија у индустријском окружењу.

ИЗЈАВА АУТОРА О ОРИГИНАЛНОСТИ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Изјављујем да докторска дисертација под насловом:

Развој модела за управљање процесом испитивања квалитета у LEAN индустријским системима базираног на методама вештачке интелигенције

представља *оригинално ауторско дело* настало као резултат *сопственог истраживачког рада*.

Овом Изјавом такође потврђујем:

- да сам *једини аутор* наведене докторске дисертације,
- да у наведеној докторској дисертацији *нисам извршио/ла повреду* ауторског нити другог права интелектуалне својине других лица,

У Крагујевцу, 10.05.2024. године,



потпис аутора

Образац 2

**ИЗЈАВА АУТОРА О ИСТОВЕТНОСТИ ШТАМПАНЕ И ЕЛЕКТРОНСКЕ ВЕРЗИЈЕ
ДОКТОРСКЕ ДИСЕРТАЦИЈЕ**

Изјављујем да су штампана и електронска верзија докторске дисертације под насловом:
**Развој модела за управљање процесом испитивања квалитета у LEAN
индустријским системима базираног на методама вештачке интелигенције**

истоветне.

У Крагујевцу, 10.05.2024. године,



потпис аутора

ИЗЈАВА АУТОРА О ИСКОРИШЋАВАЊУ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Ја, **Немања Пајић**,

дозвољавам

не дозвољавам

Универзитетској библиотеци у Крагујевцу да начини два трајна умножена примерка у електронској форми докторске дисертације под насловом:

Развој модела за управљање процесом испитивања квалитета у LEAN индустријским системима базираног на методама вештачке интелигенције

и то у целини, као и да по један примерак тако умножене докторске дисертације учини трајно доступним јавности путем дигиталног репозиторијума Универзитета у Крагујевцу и централног репозиторијума надлежног министарства, тако да припадници јавности могу начинити трајне умножене примерке у електронској форми наведене докторске дисертације путем *преузимања*.

Овом Изјавом такође

дозвољавам

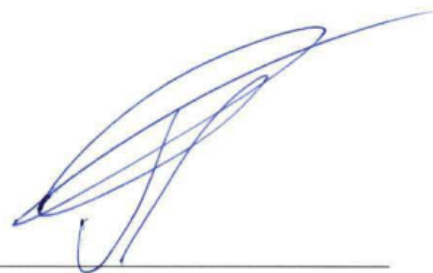
не дозвољавам¹

¹ Уколико аутор изабере да не дозволи припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од *Creative Commons* лиценци, то не искључује право припадника јавности да наведену докторску дисертацију користе у складу са одредбама Закона о ауторском и сродним правима.

припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од следећих *Creative Commons* лиценци:

- 1) Ауторство
- 2) Ауторство - делити под истим условима
- 3) Ауторство - без прерада
- 4) Ауторство - некомерцијално
- 5) Ауторство - некомерцијално - делити под истим условима
- 6) Ауторство - некомерцијално - без прерада²

У Крагујевцу, 10.05.2024. године,



потпис аутора

² Молимо ауторе који су изабрали да дозволе припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од *Creative Commons* лиценци да заокруже једну од понуђених лиценци. Детаљан садржај наведених лиценци доступан је на: <http://creativecommons.org/rs/>