



**УНИВЕРЗИТЕТ „СВ. КИРИЛ И МЕТОДИЈ“
ВО СКОПЈЕ**

МАШИНСКИ ФАКУЛТЕТ – СКОПЈЕ

Ема Влатко Василеска

**РАЗВОЈ НА ИНТЕЛИГЕНТЕН СИСТЕМ ЗА МОНИТОРИНГ НА
ПРОЦЕС ЗА АДИТИВНО ПРОИЗВОДСТВО НА ДЕЛОВИ ОД
МЕТАЛ БАЗИРАН НА ОПТИЧКА ЕМИСИОНА
СПЕКТРОСКОПИЈА И МАШИНСКО УЧЕЊЕ**

Докторски труд

Скопје, 2025



**SS. CYRIL AND METHODIUS
UNIVERSITY IN SKOPJE**

FACULTY OF MECHANICAL ENGINEERING - SKOPJE

M.Sc. Ema Vasileska

**DEVELOPMENT OF AN INTELLIGENT MONITORING SYSTEM
FOR METAL ADDITIVE MANUFACTURING BASED ON OPTICAL
EMISSION SPECTROSCOPY AND MACHINE LEARNING**

Summary of the doctoral dissertation

Skopje, 2025

Докторанд: **Ема Влатко Василеска**

Тема: „Развој на интелигентен систем за мониторинг на процес за адитивно производство на делови од метал базиран на оптичка емисиона спектроскопија и машинско учење”

Ментор:

Проф. д-р **ВАЛЕНТИНА ГЕЧЕВСКА,**

Универзитет „Св. Кирил и Методиј“ во Скопје

Машински факултет-Скопје

Коментор:

Проф. д-р **БАРБАРА ПРЕВИТАЛИ,**

Политехнички универзитет во Милано, Италија

Оддел за машинско инженерство

Комисија за одбрана:

Проф. д-р **ВЛАДИМИР ДУКОВСКИ,** претседател

Универзитет „Св. Кирил и Методиј“ во Скопје, Машински факултет-Скопје

Проф. д-р **ВАЛЕНТИНА ГЕЧЕВСКА,** ментор

Универзитет „Св. Кирил и Методиј“ во Скопје, Машински факултет-Скопје

Проф. д-р **МИТЕ ТОМОВ,** член

Универзитет „Св. Кирил и Методиј“ во Скопје, Машински факултет-Скопје

Проф. д-р **БАРБАРА ПРЕВИТАЛИ,** надворешен член

Политехнички универзитет во Милано, Италија, Оддел за машинско инженерство

Проф. д-р **АЛИ ГОКХАН ДЕМИР,** надворешен член

Политехнички универзитет во Милано, Италија, Оддел за машинско инженерство

Научна област: **МАШИНСТВО**

Датум на одбрана: 25.11.2025

АПСТРАКТ

Меѓу техниките за адитивно производство на делови од метал, ласерската фузија на слој од прав (LPBF) се издвојува како најрелевантна поради способноста за висока прецизност на печатење и можноста за изработка на решеткасти структури со тенки сидови и минијатурни димензии. Но, чувствителноста на процесните параметри и сложеноста на геометријата често водат до појава на дефекти, што ја наметнува потребата од континуирано следење на состојбата на процесот во реално време. Едни од најзначајните карактеристики што треба да се следат за проценка на стабилноста на процесот се: недостаток на депониран прав на слојот, типот на материјал при печатење со повеќе материјали, и големината на стопената зона која го одразува енергетскиот влез и стабилноста на топењето. За да се овозможи следење на овие карактеристики со еден сензор, во ова истражување се предлага коаксијално поставен мониторинг систем базиран на оптичка емисиона спектроскопија, кој овозможува истовремено набљудување на интензитетот на топење и на спектралните карактеристики на емитираната светлина во зоната на интеракција помеѓу ласерот и материјалот. Спроведен е експеримент за прибирање на спектрални податоци и за верификација на функционирањето на мониторинг системот. Статистичката анализа на податоците покажа дека варијациите во процесните параметри влијаат на интензитетот и формата на емисионите сигнали, а идентификуваните спектрални линии соодветствуваат на легирачките елементи во истражуваните метали според базата на Националниот институт за стандарди и технологија. Во истражувањето е применет интегриран аналитички пристап кој комбинира алгоритми за машинско учење и физички закони, со цел да се овозможи автоматизирано следење на процесните карактеристики и истовремено да се постигне научно засновано разбирање на процесот и температурната динамика преку анализа на спектралните информации. Развиени се модели со надгледувано машинско учење за класификација и регресија со точност над 90% при предвидувањето на дефинираните карактеристики, како и ненадгледувано машинско учење со анализа на главни компоненти за групирање на спектралните податоци според процесните услови. Дополнително, со примена на Виеновиот закон за поместување на зрачењето и методот на Болцманов график е направена квалитативна проценка на температурите на црното тело и на електроните во плазмата како функција од променливите параметри. Со резултатите од докторското истражување се воспоставува основа за интелигентен LPBF систем кој автономно го следи процесот во реално време и детектира отстапувања од номиналните услови, поддржувајќи го поширокото прифаќање и примена на адитивното производство за делови од метал во индустрискиот сектор.

Клучни зборови: адитивно производство на делови од метал; ласерска фузија на слој од прав; мониторинг во реално време; оптичка емисиона спектроскопија; машинско учење; анализа со главни компоненти; Виенов закон за поместување на зрачењето; Болцманов график

ABSTRACT

Among the techniques for metal additive manufacturing, laser powder bed fusion (LPBF) stands out as the most relevant due to its ability to achieve high manufacturing precision and produce lattice structures with thin walls and intricate features. However, the sensitivity of LPBF to process parameters and the complexity of geometries often lead to defects, highlighting the need for real-time process monitoring. Some of the most critical characteristics to monitor for assessing process stability include the absence of deposited powder on the layer, the material type in multi-material printing, and the melted spot size which reflects both the energy input and melting stability. To monitor these characteristics using a single sensor, this study proposes a coaxially positioned monitoring system based on optical emission spectroscopy (OES), enabling simultaneous observation of melting intensity and the spectral characteristics of the light emitted in the interaction zone between the laser and the material. An experiment was conducted to acquire spectral data and verify the functionality of the monitoring system. Statistical analysis of the data showed that variations in process parameters affect both the intensity and shape of the emission signals, and the identified spectral lines correspond to the alloying elements in the investigated metals, in accordance with the National Institute of Standards and Technology (NIST) database. This study employs an integrated analytical approach that combines machine learning algorithms and physical laws to enable automated monitoring of process characteristics while providing a scientifically grounded understanding of the process and its thermal dynamics through spectral data analysis. Supervised machine learning models for classification and regression were developed, achieving over 90% accuracy in predicting the defined characteristics, along with unsupervised learning using principal component analysis to cluster spectral data according to process conditions. Additionally, Wien's displacement law and the Boltzmann plot method were applied to qualitatively estimate the blackbody and electron temperatures in the plasma as functions of varying parameters. The results of this doctoral research establish a foundation for an intelligent LPBF system capable of autonomously monitoring the process in real time and detecting deviations from nominal conditions, thus supporting the broader adoption and application of metal additive manufacturing in the industrial sector.

Key words: metal additive manufacturing; laser powder bed fusion; real-time monitoring; optical emission spectroscopy; machine learning; principal component analysis; Wien's displacement law; Boltzmann plot

БЛАГОДАРНОСТ

Со искрена благодарност сакам да упатам признание до сите кои на различни начини придонесоа кон реализирањето на мојата докторска дисертација.

Посебна благодарност упатувам до мојот ментор, проф. д-р Валентина Гечевска, за нејзината континуирана поддршка, стручни насоки и довербата што ми ја укажа во текот на целиот процес, како и за нејзината инспиративна посветеност и водење кои го обликуваа овој труд. Искрено се заблагодарувам на мојот коментор проф. д-р Barbara Previtali за можноста и ресурсите да го споведам експерименталниот дел од истражувањето во лабораторија на Politecnico di Milano, како и за нејзините вредни стручни совети, подготвеноста секогаш да помогне, и за нејзиното непроценливо значење во мојот академски раст. Голема благодарност упатувам и до проф. д-р Ali Gökhan Demir за неговото несебично споделено знаење, насочување низ истражувачките активности и непроценлива помош низ сите анализи од докторатот. Својата благодарност ја изразувам и до проф. д-р Владимир Дуковски за неговото стручно мислење кое придонесе кон подобрување на дисертацијата, и до проф. д-р Мите Томов за тоа што во секое време беше достапен и подготвен да ме сослуша, да ми помогне и да ме насочи низ сите чекори од мојот академски пат.

До мојата сестра Симона упатувам најискрена и длабока благодарност за нејзината безусловна поддршка и помош, кои ми беа огромна сила низ секој чекор од ова патување. На мојата мајка Дијана, татко Влатко и дедо Цане им благодарам за вербата во мене, трпението и силната поткрепа која ми ја даваа низ целиот процес. Исто така, им се заблагодарувам и на сите останати членови од моето пошироко семејство, кои со својата присутност и охрабрување придонесоа кон мојот успех и мотивација. Од срце му благодарам на Огнен за неговата љубов, разбирање и постојана поддршка која ми донесе сила и мир во текот на овие години. На Мелани ѝ благодарам за нејзината искрена и долготрајна пријателска поддршка, за секоја охрабрувачка мисла и секој момент на присутност.

Искрено им благодарам на моите драги колеги Александар и Моника за нивното пријателство и за секој заеднички момент кој ми го олесни и разубави целиот процес на работа на дисертацијата. Благодарност упатувам и до колегите од Машинскиот факултет во Скопје и до колегите од SITEC лабораторијата на Politecnico di Milano за соработката, помошта, пријателството и убавите моменти што го збогатија моето искуство во текот на докторатот.

На сите мои другарки и другари им благодарам за позитивната енергија која ми ја даваа, дружењето и смеата кои ми го разубавуваа секојдневието.

На крај, упатувам благодарност до сите кои, иако не се споменати поединечно, на кој било начин придонесоа за успешно реализирање на оваа докторска дисертација.

Изјавувам дека докторскиот труд го изработив самостојно, дека уредно ги цитирам сите користени извори и литература и дека трудот не е користен во рамките на други универзитетски студии или за стекнување на друго звање.

Ема Василеска



Изјавувам дека електронската верзија на докторскиот труд е идентична со отпечатениот докторски труд.

Ема Василеска



СОДРЖИНА

1. ВОВЕД И ПРЕГЛЕД НА ЛИТЕРАТУРА	1
1.1. Вовед во процесот LPBF за адитивно производство на делови од метал.....	2
1.2. Дефекти во процесот LPBF	4
1.3. Мониторинг на процесот LPBF	6
1.4. Оптичка емисиона спектроскопија за мониторинг на процесот LPBF	9
1.5. Примена на машинско учење во процесот LPBF	11
1.6. Примена и мониторинг на стратегија на единечна точка на изложеност во процесот LPBF	14
1.7. Материјали во процесот LPBF	20
1.8. Мотивација за истражувањето	21
1.9. Заклучоци за поглавјето	22
2. ОПИС И СТРУКТУРА НА ИСТРАЖУВАЊЕТО	24
2.1. Предмет на истражувањето	25
2.2. Цели на истражувањето	27
2.3. Хипотези	29
2.4. Методологија на истражувањето	30
2.5. Придобивки од истражувањето	34
2.6. Заклучоци за поглавјето	35
3. ОСНОВИ НА ПРИМЕНЕТИТЕ МЕТОДИ ВО ИСТРАЖУВАЊЕТО	37
3.1. Основи на машинско учење	38
3.2. Алгоритми со машинско учење за класификација	41
3.2.1. Збиен модел со метод на засилување за класификација	41
3.2.2. Збиен модел со метод на агрегирање за класификација	46
3.2.3. Бајесов наивен алгоритам	48
3.2.4. Алгоритам k -најблиски соседи	50
3.2.5. Машини со носечки вектори	52
3.3. Алгоритми со машинско учење за регресија	58
3.3.1. Модел на регресија со Гаусов процес	59

3.3.2. Регресија со носечки вектори	62
3.3.3. Збирен модел со метод на засилување за регресија	65
3.3.4. Збирен модел со метод на агрегирање за регресија	67
3.3.5. Вештачки невронски мрежи	68
3.4. Анализа на главни компоненти	72
3.5. Метрики за евалуација на точноста на моделите со машинско учење.....	74
3.6. Физички закони применети во спектроскопијата.....	77
3.6.1. Атомски енергетски нивоа и електронски транзиции	77
3.6.2. Линиски и континуиран емисионен спектар	80
3.6.3. Виенов закон за поместување на зрачењето за проценка на температурата на црното тело.....	82
3.6.4. Метод на Болцманов график за проценка на температурата на електроните во плазмата	84
3.7. Заклучоци за поглавјето	85
4. ЕКСПЕРИМЕНТАЛНА ОПРЕМА	87
4.1. Конфигурација и оптички компоненти на експерименталната LPBF машина	89
4.2. Применет спектрометар и негови карактеристики.....	93
4.3. Развој и имплементација на мониторинг систем за оптичка емисиона спектроскопија на LPBF машина	94
4.3.1. Определување на кривата на преносливост на оптичките компоненти.....	97
4.4. Заклучоци за поглавјето	98
5. ЕКСПЕРИМЕНТИ И РЕЗУЛТАТИ.....	100
5.1. План и спроведување на експериментите	101
5.2. Мерење на дијаметрите на стопениот регион добиени од експериментите	104
5.2.1. Статистичка анализа на дијаметрите на стопениот регион.....	107
5.3. Анализа на емисионите спектри од коаксијалниот мониторинг на процесот	112
5.3.1. Статистичка анализа на спектралните податоци.....	117
5.4. Заклучоци за поглавјето	121
6. РЕЗУЛТАТИ ОД ПРИМЕНАТА НА МОДЕЛИ СО МАШИНСКО УЧЕЊЕ ЗА МОНИТОРИНГ НА LPBF ПРОЦЕСОТ	123

6.1. Методолошка рамка на предложеното истражување за имплементација на модели со машинско учење	124
6.2. Применети техники за валидација на моделите и оптимизација на хиперпараметрите.....	127
6.3. Развој, имплементација и тестирање на модели со машинско учење за класификација на типот и состојбата на материјалот	129
6.3.1. Имплементација и резултати од збирниот модел со метод на засилување за класификација	130
6.3.2. Имплементација и резултати од збирниот модел со метод на агрегирање за класификација	133
6.3.3. Имплементација и резултати од машините со носечки вектори	134
6.3.4. Имплементација и резултати од алгоритмот k -најблиски соседи	137
6.3.5. Имплементација и резултати од Бајесовиот наивен алгоритам	138
6.3.6. Споредбени анализи за точноста и брзината на предвидување на моделите со машинско учење за класификација	140
6.4. Развој, имплементација и тестирање на модели со машинско учење за регресија за предвидување на дијаметарот на стопениот регион	143
6.4.1. Имплементација и резултати од моделот на регресија со Гаусов процес.	144
6.4.2. Имплементација и резултати од регресијата со носечки вектори	146
6.4.3. Имплементација и резултати од збирниот модел со метод на засилување за регресија	148
6.4.4. Имплементација и резултати од збирниот модел со метод на агрегирање за регресија	150
6.4.5. Имплементација и резултати од вештачките невронски мрежи	151
6.4.6. Споредбени анализи за точноста и брзината на предвидување на моделите со машинско учење за регресија	154
6.5. Имплементација и резултати од анализата на главни компоненти	156
6.6. Заклучоци за поглавјето	160
7. РЕЗУЛТАТИ ОД ПРИМЕНАТА НА ФИЗИЧКИ ЗАКОНИ ПРИ СПЕКТРОСКОПСКА АНАЛИЗА ЗА МОНИТОРИНГ НА LPBF ПРОЦЕСОТ	162
7.1. Изолирање на термичката радијација и спектралните линии од емисиониот спектар со примена на алгоритам за асиметрично измазнување со метод на најмали квадрати.....	163

7.2. Квалитативна проценка на температурата на црното тело во процесот LPBF со примена на Виеновиот закон за поместување на зрачењето	167
7.3. Идентификација и анализа на спектралните екстреми на легирачките елементи	170
7.4. Квалитативна проценка на температурата на електроните во плазмата во процесот LPBF со примена на методот на Болцманов график	173
7.5. Заклучоци за поглавјето	176
8. ДИСКУСИИ.....	178
8.1. Дискусија за примената на мониторинг системот и експерименталната методологија.....	178
8.2. Дискусија за примената на моделите со машинско учење	179
8.3. Дискусија за примената на физичките закони во спектроскопијата	180
8.4. Дискусија за хибриден интелигентен мониторинг систем со синергетска примена на физички модели и машинско учење во LPBF	181
9. ЗАКЛУЧОЦИ И НАСОКИ ЗА ИДНИ ИСТРАЖУВАЊА	183
9.1. Заклучоци од осознавачки карактер	183
9.2. Заклучоци од мериторен карактер	184
9.3. Заклучоци од утилитарен карактер	186
9.4. Насоки за идни истражувања	187
Користена литература	188

Листа на слики

Слика 1.1: Шематски приказ на процесот LPBF за адитивно производство на делови од метал	3
Слика 1.2: Основни оптички елементи во систем за ласерско скенирање [5].....	3
Слика 1.3: Начин на работа и основни компоненти на спектрометарски сензор [51]	9
Слика 1.4: Области на примена на машинското учење во процесот LPBF [75].....	12
Слика 1.5: Стратегија на единечна точка на изложеност: а) шематски приказ; б) единечен ласерски пулс со моќност P и време на изложеност ton	15
Слика 1.6: а) SEM слика од добиената структура; б) металографски пресек; в) микро томографија (μ -СТ); г) приказ на дијаметарот на столбовите [105].....	16
Слика 1.7: SEM слика со големо и мало зголемување, металографски пресек и μ -СТ анализа на решеткасти структури, добиени со: а) најниско енергетско ниво; б) највисоко енергетско ниво [104]	17
Слика 1.8: Дефиниција на дијаметарот на тенките столбови, кој се совпаѓа со дијаметарот на стопениот регион од ласерот ($dmelt$): а) обработка на единечен материјал; б) обработка на повеќе материјали [123].....	19
Слика 2.1: Шематски приказ на истражуваните дефекти во процесот LPBF [123]	26
Слика 2.2: Методолошка рамка и активности во докторското истражување.....	34
Слика 3.1: Начини на програмирање на компјутер: а) традиционално; б) со машинско учење	38
Слика 3.2: Процес и фази на развој на модел со машинско учење.....	39
Слика 3.3: Поделба и категории на машинско учење	40
Слика 3.4: Шематски приказ на дрво на одлуки со негови составни елементи при машинско учење	42
Слика 3.5: Шематски приказ на принципот на работа збиен модел со метод на адаптивно засилување	46
Слика 3.6: Шематски приказ на принципот на работа на збиен модел со метод на агрегирање со повеќекратно избирање примероци.....	48
Слика 3.7: Шематски приказ на принципот на работа на алгоритмот k -најблиски соседи за $k = 3$	51
Слика 3.8: Пример со две класи и два влезни параметри (x_1 и x_2): а) три можни хипер-рамнини (R_1, R_2, R_3) за раздвојување на класите; б) дефинирање на носечки вектори и принцип на работа на машините со носечки вектори, каде се одбира оптимална хипер-рамнина преку максимизирање на маргините.....	53
Слика 3.9: Споредба на дефинирањето на хипер-рамнина кај машините со носечки вектори во зависност од примената на тврда или мека маргина	54
Слика 3.10: Влијанието на вредноста на параметарот C врз дефинирањето на маргините и позицијата на хипер-рамнината кај машините со носечки вектори	55

Слика 3.11: Демонстрација на имплементацијата на кернел функција за одделување на две класи со хипер-рамнина, каде оригиналниот простор на податоците се трансформира во повисоко- димензионален простор – слика адаптирана од [152]	57
Слика 3.12: Влијание на бројот на податоци за тренирање врз точноста и интервалот на доверба на моделот на регресија со Гаусов процес.....	60
Слика 3.13: Дефинирање на хипер-рамнината и зоната на толеранција кај моделот за регресија со носечки вектори	63
Слика 3.14: Подобрување на точноста на збирниот модел со метод на засилување со додавање на нов регресор во секоја итерација	66
Слика 3.15: Структура на вештачка невронска мрежа со влезови $x_1, \dots, x_5$, излез y , и трите типови на слоеви прикажани со нивните меѓусебни поврзувања.....	68
Слика 3.16: Приказ на операциите кои се вршат во неврон со реден број j кој припаѓа во слојот со реден број l	70
Слика 3.17: Шематски приказ на принципот на работа на алгоритмот анализа на главни компоненти	73
Слика 3.18: Шематски приказ на апсорпција и емисија на фотон при енергетски транзиции на електронот во атомот.....	78
Слика 3.19: Спектрална распределба и максимум на кривата на зрачење за различни температури на црното тело според Виеновиот закон за поместување на зрачењето [177].....	83
Слика 4.1: Шема на главата за ласерско скенирање од Raylase (Веслинг, Германија) со интегриран модул за коаксијален мониторинг и составните оптички елементи [123].....	90
Слика 4.2: Коефициент на рефлективност на галванометриските огледала	92
Слика 4.3: Коефициент на а) преносливост и б) рефлективност на дихроичното огледало инсталирано во главата за скенирање	93
Слика 4.4: Спектрометар Avantes 2048 USB2 (Avantes B.V., Апелдорн, Холандија)	93
Слика 4.5: Коаксијална имплементација на сензорот: а) шематски приказ; б) фотографија од физичкиот систем.....	95
Слика 4.6: Имплементација на сензорот надвор од оптичкиот пат на ласерот: а) шематски приказ; б) фотографија од физичкиот систем	96
Слика 4.7: Споредба на спектрите на AISI316L добиени со коаксијалната конфигурација на сензорот и конфигурацијата надвор од оптичкиот пат при $P = 200$ W и $t_{on} = 800 \mu s$, користени за проценка на кривата на преносливост на оптичките елементи	98
Слика 5.1: Шематски приказ на експерименталниот тек во различните фази на LPBF процесот.....	103
Слика 5.2: Дијаграми на интервали со 95% интервал на доверба на дијаметрите на стопените региони ($dmelt$)	108

Слика 5.3: График на поединечните влијанија на факторите врз дијаметрите на стопените региони (<i>dmelt</i>).....	111
Слика 5.4: График на влијанијата на меѓусебните интеракции на факторите врз дијаметарот на стопениот регион <i>dmelt</i>	112
Слика 5.5: Примери и споредба на емисионите спектри за двата материјали и двете состојби како функција од времето на изложеност на ласерот <i>ton</i> при константна моќност $P = 200\text{ W}$	114
Слика 5.6: Примери и споредба на емисионите спектри за двата материјали и двете состојби како функција од моќноста на ласерот P при константно време на изложеност $ton = 400\text{ }\mu\text{s}$	115
Слика 5.7: Споредба меѓу некоригирани и коригирани спектри со примена на крива на преносливост за двата материјали при $P = 200\text{ W}$ и $ton = 800\text{ }\mu\text{s}$, со означени спектрални екстреми на легирачките елементи според базата на NIST [133].....	116
Слика 6.1: Дефинирање на четирите класи кои се применети во моделите со машинско учење.....	124
Слика 6.2: Методолошка рамка за примена на моделите со машинско учење во истражувањето.....	126
Слика 6.3: Шематски приказ на принципот на работа на техниката на вкрстена валидација со 5 сегменти кај моделите со машинско учење.....	127
Слика 6.4: Чекори на имплементација на техниката на вкрстена валидација со 5 сегменти кај моделите со машинско учење.....	128
Слика 6.5: Конфузни матрици од примената на збирниот модел со метод на засилување за класификација: а) резултати од валидација, б) резултати од тестирање.....	132
Слика 6.6: Конфузни матрици од примената на збирниот модел со метод на агрегирање за класификација: а) резултати од валидација, б) резултати од тестирање.....	134
Слика 6.7: Конфузни матрици од примената на машини со носечки вектори: а) резултати од валидација, б) резултати од тестирање.....	136
Слика 6.8: Конфузни матрици од примената на алгоритмот на k -најблиски соседи: а) резултати од валидација, б) резултати од тестирање.....	138
Слика 6.9: Конфузни матрици од примената на Бајесовиот наивен алгоритам: а) резултати од валидација, б) резултати од тестирање.....	140
Слика 6.10: Споредба на добиената точност на моделите со машинско учење за класификација во фазите на валидација и тестирање.....	142
Слика 6.11: Споредба на брзината на предвидување на моделите со машинско учење за класификација.....	142
Слика 6.12: Резултати од примената на моделот на регресија со Гаусов процес за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на <i>dmelt</i> ; б) хистограм на остатоците.....	146

Слика 6.13: Резултати од примената на моделот на регресија со носечки вектори за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на <i>dmelt</i> ; б) хистограм на остатоците	148
Слика 6.14: Резултати од примената на збиен модел со метод на засилување за регресија за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на <i>dmelt</i> ; б) хистограм на остатоците	150
Слика 6.15: Резултати од примената на збиен модел со метод на агрегирање за регресија за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на <i>dmelt</i> ; б) хистограм на остатоците	151
Слика 6.16: Структура на имплементирата вештачка невронска мрежа со оптимизиран број на скриени слоеви и број на неврони во скриен слој.....	152
Слика 6.17: Резултати од примената на вештачка невронска мрежа за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на <i>dmelt</i> ; б) хистограм на остатоците.....	154
Слика 6.18: Споредба на добиената точност на моделите со машинско учење за регресија во фазите на валидација и тестирање	155
Слика 6.19: Споредба на брзината на предвидување на моделите со машинско учење за регресија	156
Слика 6.20: Дијаграм на објаснета варијанса на првите пет гллавни компоненти, каде се забележува „израмнување“ на кривата по втората компонента.....	157
Слика 6.21: График на проектирани координати во дводимензионален простор дефиниран од првите два главни компоненти, препознавајќи ги четирите дефинирани класи.....	159
Слика 7.1: Резултат од примената на алгоритмот асиметрично измазнување со метод на најмали квадрати кај Ti-6Al-4V за изолирање на термичката радијација од спектарот и одвојување на кривата со спектрални екстреми, пример со $P=200W$ и $t_{on}=800\mu s$	166
Слика 7.2: Споредба на извлечени базни линии и нивното спектрално поместување при максимален и минимален енергетски внес на ласерот за: а) Ti-6Al-4V, и б) AISI316L	168
Слика 7.3: Моделирани регресиони површини за теоретската квалитативна проценка на температурата на црното тело ($T_{ц.т.}$) во функција од влезните параметри P и ton за: а) Ti-6Al-4V, и б) AISI316L	169
Слика 7.4: Бранови должини на детектираните спектрални екстреми во експериментите и крива на спектрални екстреми од експеримент со $P=200W$ и $t_{on}=800\mu s$, со означени спектрални екстреми на легирачките елементи идентификувани според NIST [133], за: а) AISI316L; б) Ti-6Al-4V.....	172

Слика 7.5: Резултати од квалитативната проценка на температурата на електроните во плазмата со примена на методот на Болцманов график во зависност од процесните параметри: а) AISI316L; б) Ti-6Al-4V	174
Слика 7.6: Примери од линеарна регресиона линија и проценета температура на електроните во плазмата според Болцмановиот график: а) AISI316L; б) Ti-6Al-4V	175

Листа на табели

Табела 1-1: Видови дефекти и нивен опис во процесот LPBF	5
Табела 1-2: Примери на трудови за примената на различни типови на мониторинг системи и нивната цел	7
Табела 1-3: Примери на примена на машинско учење за оптимизацијата на процесните параметри	12
Табела 1-4: Примери на примена на машинско учење за in-situ мониторинг во LPBF	13
Табела 1-5: Примери на примена на машинско учење за оптимизација на дизајнот за адитивно производство	14
Табела 1-6: Примери на примена на машинско учење за редоследот на операции во производство	14
Табела 1-7: Типични материјали користени во LPBF	20
Табела 3-1: Најчесто користени кернел функции кај машините со носечки вектори	58
Табела 3-2: Најчесто користени кернел функции кај моделот на регресија со Гаусов процес	61
Табела 3-3: Основни разлики помеѓу алгоритмите со носечки вектори за класификација и за регресија	65
Табела 3-4: Најчесто применувани активациони функции кај вештачките невронски мрежи	70
Табела 4-1: Технички карактеристики на ласерот користен на LPBF машината	91
Табела 4-2: Технички карактеристики на спектрометарот Avantes 2048 USB2	94
Табела 5-1: Хемиски состав на металната легура AISI316L	102
Табела 5-2: Хемиски состав на металната легура Ti-6Al-4V	102
Табела 5-3: Фиксни и променливи фактори со нивните нивоа во експерименталниот план	103
Табела 5-4: Микроскопски слики на стопените региони за двата материјали во двете состојби добиени од експериментите со $P=200W$ и $t_{on}=200\mu s$	106
Табела 5-5: Микроскопски слики на стопените региони за двата материјали во двете состојби добиени од експериментите со $P=200W$ и $t_{on}=800\mu s$	106
Табела 5-6: Резултати од дисперзионата анализа на влијанието на факторите врз дијаметарот на стопениот регион ($dmelt$)	109
Табела 5-7: Резултати од дисперзионата анализа на влијанието на факторите врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини	118
Табела 5-8: График на поединечните влијанија на факторите P и t_{on} врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната	

емисија во VIS и NIR опсег на бранови должини кај AISI316L во прашкаста состојба	119
Табела 5-9: График на поединечните влијанија на факторите P и ton врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини кај Ti-6Al-4V во прашкаста состојба	119
Табела 5-10: График на поединечните влијанија на факторите P и ton врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини кај AISI316L - полн материјал.	120
Табела 5-11: График на поединечните влијанија на факторите P и ton врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини кај Ti-6Al-4V - полн материјал	120
Табела 6-1: Вредности на објаснета веријанса на првите пет главни компоненти добиени од анализата на главни компоненти	158
Табела 7-1: Избрани спектрални линии за примена на метод на Болцманов график и нивни карактеристики за AISI316L	173
Табела 7-2: Избрани спектрални линии за примена на метод на Болцманов график и нивни карактеристики за Ti-6Al-4V	173

1. ВОВЕД И ПРЕГЛЕД НА ЛИТЕРАТУРА

Ова поглавје го поставува мотивот и контекстот на докторското истражување преку преглед на литературата и идентификација на отворените предизвици и потреби во тековните истражувања поврзани со мониторинг на процесот на ласерска фузија на слој од прав (Laser Powder Bed Fusion - LPBF), што води кон формулирање на насока за оригинален научен придонес. Технологијата LPBF се препознава како водечка во адитивното производство на делови од метал, но е придружена со појава на различни дефекти и нестабилности во процесот, што ја наметнува потребата од мониторинг на процесот во реално време за навремено препознавање и разбирање на процесните појави.

Во таа насока, се нагласува потенцијалот на оптичката емисиона спектроскопија како напредна техника што овозможува истовремено следење на повеќе процесни карактеристики во широк опсег на бранови должини, како и примена на физички закони за подетално разбирање на термичките и спектралните појави, што е поткрепено со литературен преглед.

Анализата на големиот обем на спектрални податоци претставува значаен предизвик, кој може ефективно да се надмине со примена на машинско учење. Се презентира примената на моделите со машинско учење во различните области кај LPBF процесот.


Истражувањето се надоврзува на примената на стратегијата на единечна точка на изложеност при печатење на сложени решеткасти структури со минијатурни димензии, што овозможува контрола на термичката акумулација и динамиката на топење и зацврстување, потврдено преку литературни трудови.

1.1. Вовед во процесот LPBF за адитивно производство на делови од метал

Како еден од столбовите на Индустрија 4.0, адитивното производство го трансформираше производствениот сектор во последната деценија. За разлика од традиционалните производствени технологии за обработка со симнување на материјал или со пластична деформација, со адитивното производство се оформуваат делови додавајќи материјал слој по слој, при што можат да се користат пластики, керамика и метали [1]. Способноста да се произведуваат сложени и прилагодливи делови брзо и со минимален отпад на материјал, го прави адитивното производство атрактивна опција за многу производители кои работат со обработка на метал. Поради широката примена во индустријата, металите се обработуваат со сите седум категории на адитивно производство дефинирани со стандардот ISO/ASTM 52900:2021 [2].


Меѓу техниките за обработка на делови од метал со адитивно производство, фузијата на слој од прав со ласер, позната како ласерска фузија на слој од прав (Laser Powder Bed Fusion - LPBF), е една од најкористените и најпопуларните техники поради способноста за висока прецизност на печатење и изработка на функционални делови со минимална дополнителна обработка [3]. Во процесот LPBF, ласерски зрак поминува на дефинирани координати со што топи и спојува последователни слоеви на метален прав поставени врз подлога, формирајќи тридимензионални делови [4]. Процесот на LPBF започнува со креирање на 3D CAD модел од посакуваната геометрија на делот. Овој модел потоа се дели на слоеви со помош на специјализиран софтвер, а потоа овие слоеви се печатат еден по еден, почнувајќи од најнискиот до последниот, се додека не се изработи целиот дел. Металниот прав со дефинирана дебелина се нанесува на платформа со помош на нож за нанесување, а потоа посакуваната геометрија на слојот се топи со поместување на ласерскиот зрак на координатите каде треба да се изврши фузијата на металот. Оваа постапка уште се нарекува и скенирање на слојот со ласер. На точките на интеракција помеѓу материјалот и ласерот се создава мала стопена област, позната како зона на топење. Откако ќе се отстрани ласерската енергија, зоната на топење почнува да се лади и брзо да се зацврстува, создавајќи густа и цврста структура. По скенирањето на еден слој, платформата врз која се печати се симнува за дефинираната дебелина на слојот, а ножот за повторно нанесување рамномерно нанесува нов слој на прав. Овие три чекори: повторно нанесување на правот, ласерско скенирање на материјалот и симнување на платформата, се повторуваат за вкупниот број на слоеви, со што се изработува финалниот производ (Слика 1.1). Процесот се одвива во комора за обработка со инертна атмосфера. Во комората прво се создава вакуум, а потоа се

внесува аргон или азот за да се спречат несаканите последици врз микроструктурата на делот заради оксидација при топењето на металот.



Слика 1.1: Шематски приказ на процесот LPBF за адитивно производство на делови од метал

Системот за ласерско скенирање е составен од оптички елементи кои го фокусираат ласерскиот зрак во точка со минимален дијаметар и систем од галванометриски огледала кои се движат со мотори и го насочуваат ласерскиот зрак на платформата, маневрирајќи го за селективно топење на правот според посакуваната патека, визуелно прикажано на Слика 1.2.



Слика 1.2: Основни оптички елементи во систем за ласерско скенирање [5]

Duda et al. [6] го дефинираат LPBF како најрелевантен процес на адитивно производство за делови од метал во индустријата, припишувајќи му најголема важност и значење. LPBF овозможува производство на делови со внатрешни канали, празнини и други сложени геометриски и технолошки карактеристики со висока прецизност и повторливост, што го прави погоден за производство на метални делови со мали димензии и строги толеранции со висока индустриска вредност. Применливоста на овој процес за адитивно производство е докажана на глобалниот






пазар во индустрии како што се воздухопловната, медицинската и автомобилската [7], [8], [9]. Во воздухопловната и автомобилската индустрија, на пример, можноста за создавање делови кои се тополошки оптимизирани да ја издржат потребната носивост со минимална маса, директно влијае на намалување на тежината, а со тоа и ефикасното искористување на горивото [10], [11]. Во биомедицината, персонализираните импланти и протези според потребите на индивидуалниот пациент значително го подобруваат квалитетот на нивниот живот, овозможувајќи им подобро здравје и поголема функционалност [12], [13].

1.2. Дефекти во процесот LPBF

Сепак, својствата на металниот прав, како што се високата топлинска спроводливост, склоноста кон оксидација, високите површински напони и високата апсорптивност на ласерска енергија, можат да предизвикаат дефекти во изработениот дел, како што се порозност, топчеста формација, пукнатини, деламинација и геометриски дефекти [14], [15], [16]. Овие дефекти значително влијаат на механичките, физичките и димензионалните карактеристики на изработениот дел, зголемувајќи ги производствените трошоци и ограничувајќи ја применливоста на адитивното производство во строго регулирани индустриски области. Причините за овие недостатоци најчесто произлегуваат од несоодветно поставени процесни параметри [17], недоволна контрола на процесот [18], или комплексноста на геометријата на произведените компоненти [19], [20].

На Табела 1.1. е даден преглед на честите дефекти кои се појавуваат кај деловите од метал изработени со адитивно производство.

Табела 1-1: Видови дефекти и нивен опис во процесот LPBF

Вид на дефект	Слика	Опис
Порозност	 [21]	Заробени воздушни шуплини во делот.
Топчеста формација	 [22]	Формирање на сферично обликувани честички од зацврстен материјал.
Пукнатини	 [23]	Напукнување кога напрегањето на истегнување ја надминува максималната јакост на истегнување.
Деламинација	 [24]	Посебен случај на пукнатини, каде што пукнатините се појавуваат и се шират меѓу слоевите при што се предизвикува нивно разделување (пукнатини меѓу слоеви).
Геометриски дефекти	 [25]	Димензионални и геометриски отстапувања од номиналниот модел.

1.3. Мониторинг на процесот LPBF

За да може да се следи појавата на дефекти при процесот на обработка, потребно е да се врши мониторинг на процесот и да се собираат податоци за процесот во реално време. Постојат голем број на научни трудови во литературата кои го истражуваат следењето на процесот користејќи различни сензори за различни цели [26], [27]. Сензорите можат да бидат поставени во коаксијална конфигурација во оптичкиот ланец на ласерот, или во конфигурација надвор од оптичкиот ланец на ласерот со фиксна референтна рамка на гледање кон процесот. Придобивката на коаксијална конфигурација на поставеност на сензорот е тоа што сензорот има подвижна референтна рамка што овозможува да ја следи директната интеракција меѓу ласерскиот зрак и материјалот. Оваа конфигурација на системот за мониторинг се користи за набљудување на зоната на топење, при што референтната рамка се движи заедно со зоната и со тоа секогаш ја следи динамиката на топењето. Мониторинг системот се поставува директно во оптичкиот пат на ласерот во ласерската глава на машината при што емитираната светлина од зоната на топење се пренесува назад преку ласерскиот оптички пат до мониторинг сензорот. Недостаток на овој систем е сложеноста на неговото поставување на LPBF машината. Од друга страна, кога мониторинг системот е поставен во конфигурација надвор од оптичкиот ланец на ласерот, може да се набљудува дел или цела платформа на печатење зависно од зоната на интерес, карактеристиките на сензорот и неговата поставеност. Со оваа поставеност може да се следат поголемите процесни карактеристики како што се патеката на скенирање, дел од слој или цел слој, но не може да се следи зоната на топење. Врз база на истражувањата, во докторската дисертација се работи на имплементација на коаксијална конфигурација на сензор за целите на мониторинг во реално време на зоната на топење при LPBF процесот и издвојување на нејзини карактеристики.

Во литературата се користат различни типови на сензори во коаксијална конфигурација во процесот LPBF. На пример, пирометри и камери се користат за мерење на карактеристиките на зоната на топење [28], [29], [30] и површинската температура [31], термичките камери се користат за мерење на локалната дебелина на слојот од прав [32], сензори за акустична емисија за детекција на формација на порозност [33] и проценка на зоната на топење [34], а оптичка кохерентна томографија се користи за мерење на површинската рапавост на слојот [35]. Табела 1-2 сумира примери од литературата за примената на различни типови на мониторинг системи и целта на трудовите, за да се воочи применливоста на ваквите системи за различни цели во контекст на LPBF.


Табела 1-2: Примери на трудови за примената на различни типови на мониторинг системи и нивната цел

Наслов на труд	Автор	Мониторинг систем	Цел на истражување	Реф.
Development of an acoustic process monitoring system for SLM	Eschner et al.	Акустичен сензор	Детекција на дефекти преку звук	[36]
Defect detection in SLM by acoustic signals with deep belief networks	Ye et al.	Акустичен сензор	Откривање на порозност со машинско учење	[37]
Uncovering acoustic signatures of pore formation in laser powder bed fusion	Tempelman et al.	Акустичен сензор	Предвидување на порозност преку звучни сигнали	[38]
Comparison of melt pool dimension with in-situ monitored acoustic emission signal in laser powder bed fusion of austenitic stainless steel	S. Sung et al.	Акустичен сензор	Корелација меѓу звучен сигнал и димензии на топената зона	[34]
Sub-millisecond keyhole pore detection in laser powder bed fusion using sound and light sensors and machine learning	Z. Ren et al.	Акустичен сензор + сензор на светлина	Детекција на пори од тип keyhole	[33]
Spatially resolved acoustic spectroscopy for selective laser melting	Smith et al.	Акустична спектроскопија	Локализирање на извори на звук при дефекти	[39]
In situ measurements of layer roughness during laser powder bed fusion additive manufacturing using low coherence scanning interferometry	P. J. DePond et al.	Интерферометар со ниска кохеренција	Мерење на рапавост на површина за време на LPBF процесот	[35]
In-situ infrared thermographic inspection for local powder layer thickness measurement in laser powder bed fusion	T. Liu et al.	Инфрацрвена термална камера	Мерење на локална дебелина на слојот од прав	[32]
In situ quality control of the selective laser melting process using a high-speed, real-time melt pool monitoring system	Clijsters et al.	Камера	Следење на динамиката на зоната на топење и навремено откривање аномалии	[40]
Design of an Optical System for the In Situ Process Monitoring of Selective Laser Melting (SLM)	Lott et al.	Камера	Следење на процесот при високи брзини на скенирање	[41]
Camera signal dependencies within coaxial melt pool monitoring in laser powder bed fusion	Kolb et al.	Камера	Интерпретација на сигналот од камерата	[42]
Using machine learning to identify in-situ melt pool signatures indicative of flaw formation in a laser powder bed fusion additive manufacturing process	Scime & Beuth	Камера	Откривање на нестабилности во зоната на топење	[43]

Real-Time Observation of Melt Pool in Selective Laser Melting: Spatial, Temporal and Wavelength Resolution Criteria	L. Mazzoleni et al.	Камера	Следење на просторни и временски карактеристики на зоната на топење	[29]
In-situ quality inspection based on coaxial melt pool images for laser powder bed fusion with depth graph network guided by prior knowledge	Y. Zhang et al.	Камера	Инспекција на квалитет на топење преку слики	[30]
Implications for accurate surface temperature monitoring in powder bed fusion: Using multi-wavelength pyrometry to characterize spectral emissivity during processing	A. Fernandez et al.	Мулти-бранов пирометар	Мерење на површинска температура и карактеризација на емисивност	[31]
Assessment of optical emission analysis for in-process monitoring of powder bed fusion additive manufacturing	Dunbar & Nassar	Оптичка емисиона спектроскопија	Проценка на квалитет преку спектрална анализа	[44]
Optical tomography and machine learning for in-situ defects detection in laser powder bed fusion: A self-organizing map and U-Net based approach	Ero et al.	Оптичка томографија	Детекција на порозност во реално време	[45]
Pyrometric analysis of thermal processes in SLM technology	Pavlov et al.	Пирометар	Следење на температурен профил при топење	[46]
Melt pool temperature measurement and monitoring during laser powder bed fusion based additive manufacturing via single-camera two-wavelength imaging pyrometry (STWIP)	C. K. P. Vallabh, X. Zhao	Пирометар со две бранови должини	Мерење на температура на зона на топење во LPBF процесот	[28]
Automatic quality assessments of laser powder bed fusion builds from photodiode sensor measurements	Jayasinghe et al.	Фотодиода	Детекција на нееднаквости во слојот на прав	[47]
In situ melt pool monitoring and the correlation to part density of inconel ® 718 for quality assurance in selective laser melting	Alberts et al.	Фотодиода + компјутерска томографија	Корелација на сигнали со густина на делот	[48]
Detection of Process Failures in Layerwise Laser Melting with Optical Process Monitoring	Craeghs et al.	Фотодиода и камера	Детекција на неуспешна обработка и дефекти во процесот	[49]
Qualify-as-you-go: sensor fusion of optical and acoustic signatures with contrastive deep learning for multi-material composition monitoring in laser powder bed fusion process	Pandiyan et al.	Фузија на сензори (светло + звук)	Следење на материјална композиција со длабоко учење	[50]

1.4. Оптичка емисиона спектроскопија за мониторинг на процесот LPBF

И покрај големиот број на истражувања за мониторинг на LPBF процесот, оптичката емисиона спектроскопија (Optical Emission Spectroscopy - OES) е техника која е сеуште недоволно истражена и обработена во LPBF. OES е аналитичка техника која овозможува карактеризација на хемискиот состав на материјалите преку анализа на светлината што ја емитираат. Кога материјалот се изложува на високоенергетска искра, електроните во атомите на материјалот се возбудуваат на повисоки енергетски нивоа. При премин на електроните во своите основни состојби со пониска енергија, вишокот енергија се емитира како фотон со специфична бранова должина. Емитираната светлина од набљудуваниот процес може да се сними и анализира со користење на спектрометар, чии што основни компоненти и принцип на работа се шематски прикажани на Слика 1.3. Емитираната светлина што се усмерува кон спектрометарот најпрво се колимира со колимирачко огледало и така колимирана се насочува врз дифракциона решетка, која ја разложува светлината на нејзините составни бранови должини. Вака разложената светлина потоа се рефлектира од фокусирачко огледало и се насочува кон детектор, како што е CCD (Charge-Coupled Device) камера. Како излез, детекторот го дава спектарот на влезната светлина, односно распределбата на светлосните компоненти според нивните бранови должини.



Слика 1.3: Начин на работа и основни компоненти на спектрометарски сензор [51]

Спектарот е уникатен за секој материјал и содржи информации за неговите елементи и нивните концентрации. Прецизноста на OES се базира на фактот дека секој елемент има карактеристични енергетски нивоа и емитира светлина на точно дефинирани фреквенции. Ова ја прави OES многу чувствителна техника за идентификација на елементите во примерокот, вклучувајќи и траги од нечистотии.

Техниката за мониторинг со OES е корисна во процесите каде се обработува со ласер, бидејќи обезбедува информации за хемиската композиција на материјалот и овозможува пресметка на параметри како што се температурата и густината на електроните во пламата [52], [53]. Со идентификување на спектралните екстреми и квантифицирање на нивните интензитети во емисиониот спектар, анализата со OES може да даде квалитативни и квантитативни проценки за хемискиот состав на материјалот. Дополнително, добиените сигнали од OES може да се применат за воспоставување корелација помеѓу факторите на квалитет во LPBF и процесните параметри, врз основа на добиените спектри со примена на соодветни методи за моделирање.

Иако OES е применувана во процесите на ласерско заварување [54], [55] и ласерско депонирање на метал [56], [57], [58], бројот на истражувања за примената на OES во LPBF е релативно мал. Dunbar et al. поставиле спектрометар во конфигурација надвор од оптичкиот ланец на ласерот на фиксна локација во комората за LPBF и ја испитале варијацијата на емисиониот сигнал во однос на позицијата на дефокусирање на ласерот [59]. Во сличен труд, Dunbar и Nassar користеле фотодиоди надвор од оптичкиот пат опремени со филтер со пропуштен опсег за следење на односот на емисионата линија и континуум (line-to-continuum ratio) на хромот за време на обработката на Inconel 718 со LPBF [44]. Сепак, критичен недостаток на користење фотодиоди е нивната ограничена способност да набљудуваат само одбран тесен опсег на бранови должини. Слично на нив, RGB камерите се ограничени на видливиот опсег на бранови должини. Спектрометрите нудат предност над овие сензори бидејќи можат да набљудуваат широк опсег на информации од ултравиолетовата до близу-инфрацрвената бранова должина. Дополнително, имплементација на сензорот надвор од ласерскиот оптички пат не може да ја следи подвижната зона на топење во глобалната референтна рамка. Користењето на спектрометар коаксијално во оптичкиот ланец на ласерот овозможува регионот на гледање на сензорот да биде воден од галво-скенерот, осигурувајќи континуирано набљудување на емисијата на зоната на интеракција помеѓу ласерскиот зрак и материјалот и следејќи ја динамиката на процесот. Пример за овој пристап може да се најде во работата на Lough et al. [60], каде видливата светлина емитувана од зоната на топење и плазмата се користи за успешно да се разликуваат обичен јаглороден челик и нерѓосувачки челик. Тие исто така ја одредиле температурата на плазмата и димензиите на зоната на топење. Во поврзана студија, Montazeri et al. примениле мониторинг на спектралните интензитети на


радијацијата во опсегот на бранови должини од 350 до 1100 nm за време на обработката на Inconel 718 со LPBF, воспоставувајќи корелации помеѓу емитуваниот сигнал и потенцијалните контаминации на материјалот додека се печати [61]. Иако оптичката емисиона спектроскопија обезбедува вредни сознанија за интензитетот на топење и хемискиот состав на обработуваниот материјал преку мониторинг на спектралните карактеристики на светлината емитирана за време на директната интеракција помеѓу ласерот и материјалот, сепак нејзината примена и потенцијал во LPBF не се доволно истражени. Во докторската дисертација се истражува придонесот на имплементацијата на OES мониторинг систем во коаксијална конфигурација за следење на процесот и процесните услови во реално време, со цел да додаде вредност на досегашните сознанија за подобрување на LPBF процесот и негова поширока примена во индустрија.

1.5. Примена на машинско учење во процесот LPBF

При мониторингот на LPBF процесот се генерираат голем обем на податоци, кои со нивна анализа можат да придонесат кон разбирање на процесот, овозможувајќи воспоставување на корелации помеѓу податоците и дефектите или атрибути на квалитет на производот. Машинското учење, како дел од столбот на вештачката интелигенција во рамките на Индустрија 4.0, претставува ветувачко решение за предизвиците поврзани со обработка на големиот обем на податоци [62]. Машинското учење користи емпириски техники за моделирање преку откривање на значајни корелации меѓу податоци, и затоа претставува соодветна алатка за поврзување на процесните променливи со својствата на деловите [63], [64]. Имплементацијата на алгоритми за машинско учење за анализирање на податоците собрани од мониторинг системот на машината ја овозможува реализацијата на интелигентен систем способен за автономна контрола и самокорекција на процесните услови. Примената на алгоритми со машинско учење резултира со поголема точност на моделирање во однос на традиционалните методи на регресија при анализа на голем обем на податоци како што се слики од зоната на топење, акустична емисија и термална емисија [65], [66], [67]. Истражувањата во литературата за предвидување на различни атрибути на квалитет и идентификација на процесни аномалии во LPBF користат надгледувано машинско учење [68], [69], [70], ненадгледувано машинско учење [43], [71], [72], како и методи на машинско учење со поттикнување [73], [74].

Според истражувањата на постоечката литература, примените на машинско учење во LPBF може да се класифицираат во четири области, поделени врз основа на нивните целни решенија за различни предизвици во адитивното производство на

делови од метал [75], шематски прикажани на Слика 1.4. Овие четири категории ги опфаќаат редоследот на операции во производство, оптимизацијата на дизајнот за адитивно производство, оптимизацијата на процесните и примена на машинското учење за in-situ мониторинг во LPBF. Табела 1-3 - Табела 1-6 прикажуваат примери од релевантни научни трудови во кои се применува машинското учење во рамки на четирите дефинирани категории, заедно со постигнатите истражувачки резултати. Со in-situ мониторинг системот во комбинација со анализа на сензорските податоци понатаму може да се постигне управување во реално време со повратна врска. Докторската дисертација се фокусира на примената на машинско учење за in-situ мониторинг во реално време, со цел да се овозможи интелигентна анализа и проценка на карактеристики на процесот за време на печатењето.



Слика 1.4: Области на примена на машинското учење во процесот LPBF [75]

Табела 1-3: Примери на примена на машинско учење за оптимизацијата на процесните параметри

Автор	Процесна карактеристика	Резултати од истражувањето	Реф.
Tapia et al.	зона на топење	Конструирани сурогат-модел базиран на Гаусов процес за предвидување на длабочината на зоната на топење, олеснувајќи го изборот на оптимални процесни параметри.	[76]
Kamath et al.	зона на топење	Истражување на варијации на густина со промена на ласерска моќност и брзина, за одредување на оптимални параметри за постигнување >99% густина на делови.	[77]
Meng et al.	патека на скенирање	Креиран модел базиран на Гаусов процес за предвидување на длабочина на повторно топени поединечни траки, според ласерска моќност и брзина на скенирање.	[78]
Silbernagel et al.	патека на скенирање	Собрани слики од траки и нивна поделба во сегменти, групирајќи ги со алгоритам за машинско учење за автоматска оцена на кластерите според квалитет.	[79]
Knaak et al.	дел од слој	Обечен CNN модел на слики од дел од слој со цел предвидување на површинска рапавост и одредување на оптимални параметри преку учење со поттикнување.	[74]

Tapia et al.	-	Предвидување на порозност користејќи модели со Гаусови процеси (обучени на мерења на порозност), врз основа на ласерски параметри за избор на оптимални параметри на печатење.	[80]
Park et al.	-	Развиена вештачка невронска мрежа за поврзување на параметрите на LPBF процесот со својства на делот (сооднос на густина и површинска рапавост) за легурата Ti-6Al-4V.	[81]

Табела 1-4: Примери на примена на машинско учење за *in-situ* мониторинг во LPBF

Автор	Процесна карактеристика	Резултати од истражувањето	Реф.
Gaikwad et al.	зона на топење	Анализирана динамиката на зона на топење при различни ласерски параметри со користење на мапи на висина, податоци од пирометар и видео, применувајќи <i>sedapp</i> модел.	[82]
Mahato et al.	зона на топење	Измерена температура на зона на топење со коаксијален пирометар и тестирани модели со машинско учење за класификација за откривање дефекти.	[83]
Kwon et al.	зона на топење	Користена невронска мрежа за класификација за анализа на слики од зона на топење снимени со коаксијална камера за детекција на дефекти.	[84]
Scime et al.	зона на топење	Користени <i>in-situ</i> и <i>ex-situ</i> слики од зона на топење за класификација на 5 типови на порозност.	[43]
Zhang et al.	патека на скенирање	Користена камера за снимање поставена надвор од оптичкиот пат за следење на зона на топење, чад и ејектирани честички со цел класификација на квалитетот на делови.	[85]
Paulson et al.	патека на скенирање	Користено машинско учење за предвидување на подповршинска порозност во LPBF на Ti-6Al-4V, со калибрација на модели со инфрацрвени и рендгенски слики.	[86]
Lough et al.	патека на скенирање	Користена SWIR камера за поврзување на термални карактеристики со инженерски својства (јачина, процент на порозност, флуенца) за предвидување на својства на делови.	[87]
Baumgartl et al.	дел од слој	Применета термографска анализа со алгоритам за длабоко учење за идентификација на состојби: деламинација, метални ејектирани честички или номинална состојба.	[68]
Petrich et al.	дел од слој	Користени невронски мрежи за поврзување на слики од сечења со скенови од компјутерска томографија, давајќи информации за пори во координати <i>x,y,z</i> .	[88]
Scime et al.	цел слој	Користена компјутерска визија за автоматска анализа и класификација при нанесување прав, применувајќи ненадгледувано машинско учење.	[89]
Zhang et al.	цел слој	Генерирана мапа на параметри за распоредување на прав за утврдување на услови што овозможуваат посакувана рапавост.	[90]

Bartlett et al.	цел слој	Предвидена физичка формација на дефекти врз основа на грешки при распоредување на прав, детектирани преку 3D-DIC анализа на процес.	[91]
-----------------	----------	---	------

Табела 1-5: Примери на примена на машинско учење за оптимизација на дизајнот за адитивно производство

Автор	Резултати од истражувањето	Реф.
Chowdhury et al.	Обучена вештачка невронска мрежа (ANN) врз основа на облак од јазли добиени со анализа со конечни елементи, за геометриска компензација на STL моделот, со цел да се спречи деформација на финалниот дел.	[92]
Yao et al.	Развиена хибриден алгоритам со машинско учење за препорака на дизајнерски елементи во адитивно производство, со што се помага на дизајнери без искуство.	[93]
Shen et al.	Кодирани 3D модели како бинарни веројатносни дистрибуции и обучени конволуциски невронски мрежи (CNN) за детекција на карактеристики од процесот на деформација.	[94]
Williams et al.	Оптимизирање на ориентација на изработка според времето за изработка и масата на делот, користејќи CNN.	[95]
Zhang et al.	Имплементирање на Double-Layered Extreme Learning Machine за идентификација на насоки за печатење со што се избегнува поставување потпори кај критични области.	[96]
Shi et al.	Развиен метод за препознавање на елементи користејќи Heat Kernel Signature, со што се идентификуваат геометриски карактеристики и производствени ограничувања.	[97]

Табела 1-6: Примери на примена на машинско учење за редоследот на операции во производство


Автор	Резултати од истражувањето	Реф.
Li et al.	Применет хеуристички алгоритам за групирање на делови во посебни задачи распределени на повеќе машини за адитивно производство, со цел намалување на трошоците за производство во паралелен производствен систем.	[98]
Ransikarbum et al.	Спроведена е оптимизација со повеќе цели за распределување на машини за адитивно производство користејќи мешано целобројно линеарно програмирање, земајќи ги предвид оперативните трошоци, рамнотежата на оптоварување, доцнењето и неиспечатените делови.	[99]
Fera et al.	Користен е генетски алгоритам за оптимизација на распоредот за една машина за адитивно производство, обезбедувајќи навремено завршување на задачите со минимални трошоци за производство.	[100]

1.6. Примена и мониторинг на стратегија на единечна точка на изложеност во процесот LPBF

Побарувачката за ефикасно производство на сложените решеткасти структури возможни само со адитивно производство ја истакнува потребата од нови стратегии за скенирање во LPBF процесот. Традиционалните методи за скенирање во LPBF се

базираат на континуирана бранова (Continuous Wave - CW) ласерска емисија, каде брзоподвижен ласерски зрак селективно го топи слојот од прав, слој по слој. Сепак, при скенирање на тенките столбови на решеткастите структури со CW емисија, може да се појават дефекти поради нерамномерна дистрибуција на температурата во рамките на векторите на скенирање [18]. Истражувањата покажуваат дека користењето на пулсна бранова (Pulsed Wave - PW) ласерска емисија може да ја контролира временската термичка акумулација и со тоа однесувањето на топење и зацврстување на зоната на топење [101], [102].


Во последните неколку години, искористувајќи го малиот дијаметар на ласерскиот зрак и високиот степен на слобода и прецизност на LPBF процесот, истражувачите примениле алтернативна стратегија за скенирање позната како стратегија на единечна точка на изложеност (Single Point Exposure - SPE) [103], [104]. Стратегијата SPE се состои од позиционирање на ласерскиот зрак на прецизни координати, кои потоа се изложуваат на единечен ласерски пулс карактеризиран со одредено времетраење (t_{on}) и ласерска моќност (P) [104]. На Слика 1.5 е даден шематски приказ на SPE стратегијата и на ласерски пулс. Галванометриските огледала го движат ласерскиот зрак до предодредената позиција и потоа го запираат на позицијата каде што слојот од прав е изложен на единечен ласерски пулс. Земајќи ги во предвид типичните времиња на пораст и на задоцнување на комерцијалните CW ласерски извори со оптички влакна, обликот на единечниот пулс може да се смета дека е приближно квадратен, а P може да се смета како ласерска емисиона моќност во времетраењето на t_{on} на пулсот [105]. Комбинацијата на параметрите на пулсацијата на ласерот влијае на динамиката на топење за време на LPBF процесот, создавајќи кружна зона на топење со одреден дијаметар. Покажано е дека стратегијата SPE за скенирање е корисна за подобрување на минималните димензии што можат да се добијат во споредба со конвенционалните векторски стратегии на скенирање [105].



Слика 1.5: Стратегија на единечна точка на изложеност: а) шематски приказ; б) единечен ласерски пулс со моќност P и време на изложеност t_{on}

Ово докторски труд се надоврзува на претходно спроведено истражување во истата лабораторија каде што беше спроведено и ова истражување, односно во SITEC (Laboratory for Laser Applications), Оддел за машинско инженерство, сектор за производство и производни системи при Политехничкиот универзитет во Милано (Department of Mechanical Engineering - Manufacturing and Production Systems, Politecnico di Milano, Italy) [104], [105]. Во споменатото истражување беше покажан потенцијалот на стратегијата на единечна точка на изложеност за печатење на решеткасти структури. Сепак, покрај позитивните резултати, беше покажан и истражувачкиот јазол поврзан со следењето и разбирањето на процесната динамика, што создаде истражувачки прашања на кои се фокусира оваа докторска дисертација.


Истражувањата демонстрираат дека со примена на SPE стратегијата е можно целосно да се зацврстат Zn-0.5Mg решеткасти структури, со дијаметар на столбовите во опсег од 130 до 350 μm , што е значително помалку од технолошките граници наведени во литературата [106], [107], [108]. На Слика 1.6 е прикажан детален приказ на добиените структури, каде е покажана слика од скенирачка електронска микроскопија (Scanning Electron Microscope - SEM), металографски пресек и микро-томографија ($\mu\text{-CT}$), како и приказ на дијаметарот на столбовите [105].



Слика 1.6: а) SEM слика од добиената структура; б) металографски пресек; в) микро томографија ($\mu\text{-CT}$); г) приказ на дијаметарот на столбовите [105]

Резултатите од ова истражување потврдуваат дека стратегијата со единечна точка на изложеност е ефикасно решение за изработка на решеткасти структури, при што значително се намалува создавањето на пареа, искри и исфрлени честички при процесот на топење, што обично е предизвик при печатење со векторски стратегии. Дополнително, анализата на металографските пресеци не открива значително присуство на пори во структурата [104].

Во рамките на истото истражување, за првпат беше спроведен мониторинг на процесот со висока просторна и временска резолуција со камера поставена надвор од оптичкиот пат на ласерот, за време на изложување со единечен пулс врз слој од прав од Zn легура [104]. Снимките ја покажаа динамиката на процесот за време на интеракцијата помеѓу ласерот и правот и разликите во структурата и димензиите при различни нивоа на внесена енергија, прикажани на Слика 1.7. Резултатите покажаа дека при ниски нивоа на ласерска енергија се постигнува само површинско или локализирано синтерување, со што не може да се формира структура. Од друга страна, при повисоки нивоа на ласерска моќност и време на изложеност на ласерот, се забележува пареа и почеток на испарување што може да резултира со порозност во делот.




Слика 1.7: SEM слика со големо и мало зголемување, металографски пресек и μ -CT анализа на решеткасти структури, добиени со: а) најниско енергетско ниво; б) највисоко енергетско ниво [104]

Спроведените експерименти на кои се надоврзува овој докторски труд покажаа дека решеткасти структури можат успешно да се печатат со користење на SPE стратегијата, во рамките на јасно дефиниран опсег на параметри [104], [105]. Сепак, постоечката литература претежно се фокусира на векторските стратегии на

скенирање. Иако дефектите што се присутни во векторскиот LPBF процес се слични на оние во SPE-базираниот LPBF процес, дополнителни проблеми се јавуваат поради малите димензии на столбовите на решеткастите структури и ограничената временска интеракција помеѓу ласерот и материјалот. Врската помеѓу процесните параметри и резултирачката густина, микроструктурата и механичките својства на решеткастите структури е истражена во ограничен број на трудови [109], [110], [111], [112], [113]. Стратегијата SPE претходно е применета во процесот на LPBF на материјали како што се титаниумски легури и AISI316L, резултирајќи со намалување на дефектите во критичните геометрии на деловите [103], [114].

Решеткастите структури можат да се испечатат со повеќе материјали во нивната структура, при што различни метали се нанесуваат на различни слоеви за време на изработката. Иако процесните параметри можат да се оптимизираат за специфичниот материјал и геометрија на делот, сепак може да има дефекти на изработените делови поради проблеми поврзани со материјалот, контаминација на материјалите, критични геометриски карактеристики на деловите или дефекти на опрема [115], [116]. На пример, оштетување на ножот за повторно нанесување на прав или присуство на стопени честички што се прилепуваат на ножот може да предизвикаат неправилно нанесување на метален прав и, следствено, отсуство на прав на траките на скенирање во слојот [117], [118]. Ова може да доведе до феноменот на денудација, карактеризиран со недостаток на нанесен метален прав на траките на скенирање [119], значително зголемувајќи ја веројатноста за порозност и влошување на површинската рапавост на изработените делови [120]. Според извршениот преглед на постоечката литература, досега нема трудови за користење на коаксијални OES сигнали за детекција на појавата на дефект на денудација. Друго, варијациите во дистрибуцијата на температурата при топењето може да се заради критични области во дизајнот (како мост, остар раб, надвиснат раб) кои можат да предизвикаат нерамномерни услови на топење, што пак може да доведе до внатрешни дефекти како порозност од преголемо топење, недостаток на фузија или испакнати рабови [18], [86]. Мониторинг на секоја точка на емисија за време на SPE скенирањето може да придонесе за подобро разбирање на локалната процесна динамика и дистрибуцијата на температурата, овозможувајќи набљудување на интеракцијата помеѓу ласерот и материјалот, појава на потенцијални дефекти и можности за управување со повратни информации [101]. Понатаму, од голема корист е способноста за идентификација на материјалот што се печати со LPBF бидејќи овозможува автоматски избор на соодветни процесни параметри, како и детекција на контаминација на материјалот. Литературата во ова поле е доста ограничена и постојат мал број на трудови. Drissi-Daoudi et al. [121] имплементирале сензор за воздушна акустична емисија кој, комбиниран со машинско учење, ги разликува обработуваните материјали. Narayanan et al. [122] користеле две NIR камери поставени надвор од оптичкиот ланец на ласерот за да соберат податоци за

автоматска дистинкција на два материјали печатени во LPBF (AlSi10Mg и IN718). Pandiyan et al. [50] создале систем за фузија на сензори за снимање на акустични и оптички сигнали за мониторинг на LPBF со повеќе материјали со цел да го предвидат составот на материјалот. Сета постоечка литература нагласува дека точната идентификација на материјалот за време на процесот на печатење е од клучно значење за мулти-материјалното LPBF, бидејќи директно влијае на квалитетот и својствата на финалниот производ. Конечно, доколку е познат дијаметарот на тенките столбови на решеткастата структура (означени со d_{melt} на Слика 1.8) при печатењето тогаш може да се проверат номиналните дизајнирани димензии и реално депонираната геометрија, овозможувајќи детекција на прекумерно или недоволно топење, што укажува на неадекватен влез на енергија.



Слика 1.8: Дефиниција на дијаметарот на тенките столбови, кој се совпаѓа со дијаметарот на стопениот регион од ласерот (d_{melt}): а) обработка на единечен материјал; б) обработка на повеќе материјали [123]

Иако многу методи се истражени во литературата за следење на интензитетот на топење и големината на зоната на топење за време на ласерското скенирање во CW и PW режим, според извршеното истражување на постоечката литература, досега не постои објавена истражувачка работа за мониторинг на процесот при скенирање со SPE стратегија во LPBF. Причината за ова е бидејќи оваа стратегија е релативно нова во LPBF процесот и во последните неколку години почнува да се развива, но научните истражувања веќе го покажуваат нејзиниот голем потенцијал при печатење на решеткасти структури. Врз основа на извршениот преглед на постоечките научни истражувања, во докторската дисертација се работи на мониторинг во реално време на LPBF процесот со OES при стратегија на единечна точка на изложеност, со цел детекција на дефектот на денудација, идентификација на материјалот и проценка на големината на тенките столбови на решеткастата структура.

1.7. Материјали во процесот LPBF

Во процесот LPBF изборот на материјал има суштинско значење за крајниот квалитет и примена на изработениот дел. Материјалите кои се користат во LPBF треба да имаат добра обработливост со ласер, соодветна термичка спроводливост, стабилност на микроструктурата, како и добри механички својства по процесирањето. Најчесто се применуваат легури на нерѓосувачки челик, титаниум, алуминиум, никел и кобалт-хром, кои покриваат широка палета на индустриски и биомедицински потреби [124]. Типичните материјали кои се користат во LPBF, нивните карактеристики и примена се сумирани во Табела 1-7.

Табела 1-7: Типични материјали користени во LPBF

Материјали	Својства	Примени	Примери на легури
Челик и легури на железо	Висока отпорност на корозија; висока јакост (помала еластичност); релативна густина (>90%); лесна машинска обработка,	Медицински и биомедицински примени (на пр., импланти); стоматолошки производи (на пр., ортодонтски производи); разменувачи на топлина; лесни структури (на пр., хексагонални решетки); производствена индустрија	Fe-Ni, Fe3Al, Fe-Ni-Cr, Fe-Ni-Cu-P, 304L нерѓосувачки челик, 316L нерѓосувачки челик, H13 алатен челик, H20 алатен челик, Ултра-високојаглероден челик
Легури на титаниум	Висока релативна густина (>98%); висока јакост; ниска порозност; одлична биокompatibilност, висока отпорност на корозија	Биомедицински и стоматолошки примени (на пр., протези за тело, стоматолошки импланти); решеткасти структури со мала тежина	CP-Ti, Ti-6Al-4V, Ti-6Al-7Nb, Ti-24Nb-4Zr-8Sn, Ti-13Zr-Nb, Ti-13Nb-13Zr
Легури на никел	Отпорност на висока температура; отпорност на замор; одлична отпорност на оксидација и корозија; отпорност на абеење; релативна густина (речиси 100%)	Авионски мотори; комори за согорување; калапи за модели; порозни медиуми за филтрирање; турбини	Inconel 625, Inconel 718, Chromel, Hastelloy X, Nimonic 263, IN738LC, MAR-M-247, Ni-Ti
Други метали (легури на алуминиум, бакар, кобалт-хром, волфрам, злато, сребро)	Висока релативна густина кај алуминиум и кобалт-хром (>96%) и други метали (82%-85%); висока јакост кај алуминиум (на пр., 400 МПа за AlSiMg); добра термичка и електрична спроводливост на алуминиум, зголемена тврдост со додавање на бакарен прав	Биомедицински и стоматолошки примени (на пр., коронки и мостови); разменувачи на топлина; автомобилски делови; воздухопловна индустрија; електронски компоненти; накит	Al6061, AlSi10Mg, Cu+Cu10Sn+Cu8.4P, CoCr, 24-каратно злато, Волфрам, K220, CuNi15C18400

За целите на ова истражување се испитуваат две метални легури: AISI316L нерѓосувачки челик и Ti-6Al-4V титаниумска легура, бидејќи тие се едни од најчесто користените материјали во LPBF за изработка на решеткести структури, со примена во воздухопловната индустрија, биомедицината, автомобилската индустрија и енергетскиот сектор. Тие се избрани и поради нивната одлична обработливост во LPBF процес, стабилна микроструктура, добри резултати во механичките својства по печатењето, како и нивната релевантност во научната литература [125], [126].

1.8. Мотивација за истражувањето

Анализата од досегашите истражувања ја покажа потребата за креирање на паметна машина која ќе го унапреди адитивното производство на делови од метал со LPBF како современа производна технологија која е сè уште недоволно истражена, со крајна цел да биде пошироко прифатена во индустријата. Кога ќе се спореди со методите на конвенционална обработка, LPBF обработката сеуште резултира со значителен број на дефекти во финалниот производ кои што го ограничуваат потенцијалот и примената на процесот. Но, и покрај недостатоците, LPBF нуди суштински предности како што се заштедата на материјал, можноста за изработка на комплексни форми како што се решеткастите структури и прилагодливоста на дизајнот за секој корисник, што даваат силна мотивација за да се работи на усовршување на технологијата. Мониторингот на дефектите и потенцијално нивното елиминирање ќе ја издигне технологијата на уште повисоко ниво, овозможувајќи нејзина поширока примена во строго регулираните индустрии, со што ќе се заштедат материјали и трошоци и ќе се овозможи приспособлив дизајн.

Дополнително, креирањето на паметна LPBF машина претставува чекор кон воведување на интелигентни решенија во индустријата, согласно технологиите на индустриската револуција Индустрија 4.0. Со примената на напредни технологии како машинското учење и вештачката интелигенција, може да се развијат системи кои ќе можат самостојно да го следат и контролираат процесот. Ова не само што ќе ја подобри прецизноста и квалитетот на производите, туку и ќе го намали времето на производство и трошоците за одржување.

Еден од главните предизвици во LPBF е следењето и елиминацијата на дефектите. Со имплементација на напредни мониторинг системи и алгоритми за машинско учење, може да се идентификуваат и корегираат потенцијалните проблеми во реално време, што ќе резултира со повисок квалитет на финалните производи [101]. Иако машинското учење е релативно нова и напредна технологија за анализа и обработка на големи количини на податоци со висока точност, сепак не треба да се занемарат и физичките закони кои се од суштинско значење за подобро разбирање на

процесите. Во докторската дисертација се комбинираат двата пристапи - машинско учење и анализа базирана на физички закони, за да се добие целосна слика за процесот, да се идентификуваат потенцијалните проблеми и решенија, и да се придонесе во научната литература за подобро разбирање на процесот. Машинското учење се користи за обработка и анализа на големите количини на податоци собрани за време на производниот процес со коаксијалниот OES систем за мониторинг, овозможувајќи откривање на шеми и корелации кои би биле тешки за идентификација со традиционалните методи. Сепак, за подетален поглед во динамиката на процесот, исто така се спроведува и анализа базирана на физичките закони кои ги регулираат процесите на топење и интеракција на материјалите со ласер преку користење на спектрална емисија. Комбинирањето на овие два пристапи овозможува подлабоко разбирање на процесот и воедно овозможување методологија за подобрување на квалитетот и ефикасноста на LPBF производството.

1.9. Заклучоци за поглавјето

Прегледот на литературата и релевантните научни истражувања овозможи идентификација на недоволно истражени области и дефинирање на оригинална насока на истражувањето во докторската. Целта е да се прошири постоечкото знаење за технологијата LPBF за адитивно производство на делови од метал и истовремено да се анализира досега воопшто или недоволно истражена проблематика, со цел понатамошно унапредување на процесот и неговата индустриска применливост. Од ова поглавје произлегуваат следните клучни заклучоци:

- LPBF овозможува производство на тенки решеткасти структури кои се применуваат во биомедицински, воздухопловни и автомобилски апликации. Во последните неколку години, искористувајќи го малиот дијаметар на ласерскиот зрак и големата прецизност на LPBF процесот, истражувачите ја применуваат стратегијата за скенирање позната како стратегија на единечна точка на изложеност (SPE) за печатење на решеткасти структури.
- Во процесот на печатење со SPE стратегија од клучна важност е навремена детекција на дефектот на денудација, идентификација на материјалот и проценка на големината на тенките столбови на решеткастата структура, што може да се постигне преку мониторинг системи кои го следат процесот во реално време.
- Следењето на овие карактеристики со само еден сензор е возможно со оптичката емисиона спектроскопија (OES) со што може да се врши мониторинг на хемискиот состав, интензитетот на топење и динамиката на

процесот. Сепак, нејзината примена во LPBF досега е истражена во ограничен број научни трудови.

- Според извршеното истражување на постоечката литература, досега не постои објавена истражувачка работа за мониторинг на процесот при скенирање со SPE стратегија во LPBF, што претставува отворен истражувачки предизвик.
- Дополнително, досега нема научни трудови за користење на коаксијални OES сигнали за детекција на појавата на дефект на денудација.
- Способноста за идентификација на материјалот преку спектроскопски податоци е од голема важност за мулти-материјално печатење, но оваа тема исто така е недоволно разработена во досегашните трудови.
- Потенцијалот за проценка на реалните димензии на тенките решеткасти структури за време на печатењето преку мониторинг е детектиран како можност за подобрување на контролата на квалитетот и елиминирање на дефекти поврзани со неправилен енергетски влез.
- Комбинирањето на in-situ OES мониторинг со алгоритми на машинско учење се посочува како клучен чекор за создавање на интелигентен систем за автоматизирана анализа и оптимизација на процесот во реално време.
- Примената на OES мониторинг овозможува дополнителна анализа од физички аспект преку моделирање и анализа на динамиката на топењето и интеракцијата на материјалите со ласер со помош на физички закони од областа на спектроскопијата.
- Овие празнини во научната литература ја дефинираат и мотивираат содржината и насоката на докторската дисертација, која е насочена кон развој на интелигентна машина за LPBF со коаксијален OES мониторинг систем, со интеграција на машинско учење и физички закони за детекција на дефекти, идентификација на материјали и анализа на топењето во реално време.


2. ОПИС И СТРУКТУРА НА ИСТРАЖУВАЊЕТО

По спроведениот преглед на релевантната литература и анализа на досегашните истражувања, идентификуван е истражувачкиот јаз, со што се утврди и се дефинира предметот на истражувањето. Потоа, во ова поглавје се дефинираат целите на истражувањето, се формулираат три истражувачки хипотези и се опишува методологијата според која е реализирано истражувањето. Поглавјето завршува со претставување на очекуваните придобивки од истражувањето, особено во насока на развој на интелигентни системи за мониторинг со интеграција на машинско учење, како предуслов за проширување на применливоста и довербата во LPBF технологијата во индустриски услови.

2.1. Предмет на истражувањето

Во докторската дисертација се развива методологија за мониторинг на три значајни аспекти во SPE-базирано LPBF: детекција на дефект на денудација, идентификација на материјалот кој се печати и проценка на големината на тенките столбови на решеткастата структура. Дополнително, презентира истражување со физички закони за квалитативна проценка на температурата на црното тело со Виеновиот закон на поместување на зрачењето [127] и температурата на електроните во плазмата со примена на методот на Болцмановиот график [128]. За да се изведе Виеновиот закон за поместување, најпрво е проценета базната линија на термалната емисија на спектарот со методот на асиметрично измазнување на крива со метод на најмали квадрати [129]. За сите овие цели да се испитаат користејќи еден мониторинг сензор имплементиран коаксијално на LPBF машината користена е оптичка емисиона спектроскопија, бидејќи со овој метод се обезбедува поглед и во интензитетот на топење и во хемискиот состав на обработениот материјал преку мониторинг на спектралните карактеристики на светлината емитирана за време на директната интеракција помеѓу ласерот и материјалот.

Во LPBF процесот, процесот на топење е придружен со формирање на одредени феномени како што се распрскувања и плама исфрлена од зоната на топење (“облак” од испарен материјал, чад и честички). Пламата се создава кога површинската температура на зоната на топење ја достигнува точката на вриење. Предложената методологија за мониторинг со сензор за OES го искористува фактот дека различни процесни услови предизвикуваат разлики во пламата предизвикана од ласерот, кои спектрометарот ги снима, и овие варијации се користат за набљудување и проценка на тековните процесни услови [130] (Слика 2.1). Дополнително, димензиите на регионот стопен од ласерот влијаат на формирањето на пламата [131], што се користи за проценка на големината на дијаметарот на тенките столбови во решеткастата структура врз основа на добиените сигнали. Ова дава можност за проверка дали депонираната геометрија соодветствува со иницијално дизајнираната и колкаво е отстапувањето, овозможувајќи детекција на појава на прекумерно или недоволно топење.



Слика 2.1: Шематски приказ на истражуваните дефекти во процесот LPBF [123]

Предложената методологија ги користи сигналите од сензорот за мониторинг на процесот на изработка на решеткестата структура и, врз основа на овие сигнали, ја оценува стабилноста на процесот согласно оние атрибути кои се анализираат. Спроведен е експеримент за да се соберат податоци адекватни за да се истражи појавата на недостаток на прав на депонираниот слој, детекција на типот на материјал, и за проценка на дијаметарот на столбовите на решеткастата структура, користејќи ја OES спектралната емисија добиена за време на SPE печатењето. Понатаму, експерименталните податоци се користат за квалитативна проценка на температурата на црното тело и температурата на електроните во плазмата генерирана за време на процесот, користејќи физички закони. За целите на ова истражување се испитуваат две метални легури: AISI316L нерѓосувачки челик и Ti-6Al-4V, бидејќи се едни од најчесто користените материјали за изработка на решеткести структури, наоѓајќи широка примена во воздухопловната индустрија, биомедицината, автомобилската индустрија и енергетскиот сектор [125], [126]. Заради големиот обем на податоци кои се собрани за време на експериментите, како и нивната висока комплексност и нелинеарност, се користи машинско учење како соодветна и ефикасна алатка за нивна анализа.

Предложената методологија започнува со директниот спектар добиен од коаксијалниот спектрометар при SPE ласерско скенирање на соодветниот материјал, кој потоа се корегира користејќи ја кривата на преносливост на оптичките елементи во ласерскиот оптички ланец за да се извлече коригираниот спектар што не е под влијание на преносливоста на елементите. Овој коригиран спектар е влез за класификацискиот модел на машинско учење, кој потоа го идентификува специфичниот тип на материјал и детектира дали има недостаток на прав врз слојот. Предвидената класа заедно со коригираниот спектар потоа се влез во регресиониот модел на машинско учење, кој ја предвидува големината на топената зона од ласерот, односно дијаметарот на столбот во решеткестата структура. Различни соодветни модели на машинско учење се тестирани и нивната изведба е оценета, на крајот избирајќи го оној кој ја моделира корелацијата на податоците со највисока точност. Дополнително, идентификација на материјалот се врши и со Анализа на главни компоненти (Principal Component Analysis - PCA) како ненадгледуван метод на машинско учење, кој има за цел да ја намали димензионалноста на влезните спектрални емисиони податоци [132]. Со тоа се тестира точноста на моделот за идентификација на материјалот при што влезот е од пониска димензија со задржани значајни карактеристики.

Со овој рамковен модел се поставуваат основите на интелигентен LPBF систем кој со помош на мониторинг во реално време со OES сензор и алгоритми на машинско учење е способен да ја следи состојбата на процесот и да биде свесен за појава на аномалии.

2.2. Цели на истражувањето

Основни цели на докторската дисертација се:

Цел 1: Добивање продлабочени знаења за процесот LPBF за адитивно производство на делови од метал и за методите на машинско учење:

- Стекнување напредни теоретски знаења за процесите на адитивно производство на делови од метал, со посебен фокус кон LPBF техниката.
- Стекнување практични вештини за управување со машина за LPBF печатење на метал, како и потребниот софтвер, електроника, и системи за мониторинг.
- Стекнување продлабочени знаења за примената на науката за обработка на податоци и методи на машинско учење.

Цел 2: Развивање на рамковен модел за паметна машина за адитивно производство на делови од метал која ја следи стабилноста на процесот во реално време користејќи сигнали на спектрална емисија:

- Креирање рамковен модел на мониторинг на LPBF процесот во реално време, кој вклучува анализа на сигналите на спектрална емисија со алгоритми на машинско учење за да се следат истражуваните показатели на квалитет и да се детектираат аномалии при обработката, со цел подобар квалитет и прецизност на изработените производи.

Цел 3: Развој и имплементација на мониторинг системи за оптичка емисиона спектроскопија (OES) на LPBF машина – коаксијален и надвор од оптичкиот ланец на ласерот:

- Изработка на стезен прибор и избирање и поставување мониторинг системи за OES на LPBF машината, еден коаксијално во оптичката глава и еден надвор од неа. Системот надвор од оптичката глава се користи исклучиво за откривање на кривата на преносливост на оптичките елементи во оптичкиот ланец на ласерот, овозможувајќи прецизно мерење и корекција на спектралните податоци од коаксијалниот мониторинг систем.
- Постигнување синхронизација помеѓу LPBF процесот и аквизицијата на мониторинг системот преку сигналите од контролната картичка на машината, со што се одржува кохерентност помеѓу добиениот сигнал и тековниот експериментален процес.

Цел 4: Спроведување на експерименти на LPBF машината со поставен мониторинг систем:

- Изведување експерименти на метали користејќи ги двата сензорски системи, со цел проценка на кривата на преносливост на оптичките елементи во главата за скенирање и корекција на директните спектрални емисии добиени од коаксијалниот мониторинг систем.
- Изведување на експерименти на различни метални легури со варијација на процесни параметри со SPE стратегија, за да се соберат соодветен број на податоци од спектралните емисии потребни за моделирање со машинско учење.

Цел 5: Анализа на податоците за спектралните емисии при процесот на LPBF со примена на алгоритми за машинско учење:

- Развивање и примена на алгоритми за надгледувано машинско учење со класификација со цел детектирање на дефектот на денудација на слојот за време на процесот на обработка, користејќи ги сигналите од спектралната емисија.
- Развивање и примена на алгоритми за надгледувано машинско учење со класификација со цел да се идентификува материјалот кој што се печати во процесот на обработка користејќи ги сигналите од спектралната емисија. Во методологијата е вклучен оној алгоритам кој резултира со најголема точност при моделирањето.

- Примена на алгоритми со употреба на анализа на главни компоненти (PCA) за идентификација на различни материјали за време на процесот преку сигналите од спектрална емисија, со што се намалува димензионалноста на влезните податоци преку трансформација на голем број променливи во помало множество кое ги задржува клучните информации од оригиналното множество на податоци.
- Развивање, примена и споредба на алгоритми за надгледувано машинско учење со регресија за анализа на сигналите од спектралната емисија за проценка на дијаметарот на зоната на топење, а со тоа и на дијаметрите на тенките столбови од решеткастите структури изградени со стратегија на единечна точка на изложеност. Во методологијата е вклучен оној алгоритам кој резултира со најголема точност при моделирањето.

Цел 6: Примена на физички закони при анализа на податоците од спектралните емисии на LPBF процесот:

- Примена на методот на асиметрично измазнување на крива со метод на најмали квадрати за да се процени базната линија на термалната емисија на спектарот која соодветствува на обликот на термалниот ефект во спектралната емисија.
- Примена на резултатите добиени од базната линија на термалната емисија во Виеновиот закон на поместување на зрачењето за квалитативно да се процени температурата на црното тело во зависност од влезните променливи во процесот.
- Развивање на алгоритам кој автоматски ги издвојува и анализира спектралните екстрими од емисионите сигнали и ги споредува со базата на податоци на Националниот институт за стандарди и технологија (NIST). Ова ќе потврди дали екстремите соодветствуваат со обработуваниот материјал и ќе ја верификува точноста на мерењата.
- Примена на методот на Болцманов график на спектралните емисиони податоци добиени од експериментите и податоците од Atomic Spectra Database на NIST [133], со цел квалитативно да се процени температурата на електроните во плазмата во зоната на топење во зависност од влезните променливи во процесот.

2.3. Хипотези

Базирајќи се на стекнатото практично искуство и продлабочената анализа на актуелната и релевантна литература, истражувањата во докторската дисертација ќе бидат насочени кон потврдување на следниве научно-истражувачки хипотези:

Хипотеза 1. Оптичката емисиона спектроскопија може успешно да се примени во процесот на ласерска фузија на слој од прав (LPBF) за креирање на интелигентна машина за адитивно производство на делови од метал која ќе го следи процесот во реално време и ќе обезбедува спектрални податоци за материјалот, соодветни на базата на податоци на Националниот институт за стандарди и технологија (NIST), при што интензитетот на сигналите ќе зависи од процесните параметри.

Хипотеза 2. Спектралната емисија од коаксијалниот сензор за оптичка емисиона спектроскопија во LPBF, користејќи алгоритми за надгледувано машинско учење со класификација и регресија и алгоритми за ненадгледувано машинско учење со анализа на главни компоненти, со успех може да се користи за идентификација на материјалот што се печати, за детекција на дефектот на денудација и за прецизна проценка на дијаметрите на тенките столбови од решеткастите структури изградени со стратегија на единечна точка на изложеност.

Хипотеза 3. Примената на физички закони при анализа на спектралните емисии од процесот овозможува подобро разбирање на динамиката на топење и термалниот интензитет во LPBF процесот, преку квалитативна проценка на температурата на црното тело со Виеновиот закон и температурата на електроните во плазмата при процесот на топење со Болцмановиот график.

2.4. Методологија на истражувањето

При истражувањето се применети следните научно-истражувачки методи:

- **Метод на преглед (теоретски истражувања)**

Направен е детален преглед на научната и стручната литература во областа на адитивното производство на делови од метал со LPBF. Пребарани се базите на податоци со научни трудови (Web of Science, Scopus, Google Scholar, Research Gate, преземање и анализа на научните трудови со отворен пристап, како и пристапување до трудовите со затворен пристап преку Science Direct) и извлечени се информации за примената на машинско учење во LPBF, методите за мониторинг на процесот, предизвиците при примената на одредени материјали, комплексноста при печатење на сложени геометрии, како и новите трендови и предизвици во LPBF. Од деталниот преглед се сублимираа областите кои сè уште не се истражени, но имаат голем потенцијал за развој и пошироко прифаќање на LPBF во индустријата. Така се разви темата на истражувањето, која се фокусира на хардверот и софтверот кои може да се применат во LPBF како целосен интелигентен систем со голем потенцијал за печатење на решеткасти структури, за кои сè уште нема или има ограничени научни истражувања.

- **Индуктивно - дедуктивен метод**

При индуктивното расудување како почетна постапка во процесот на спознавање и истражување се оди од конкретното кон општото, при што се почна со собирање на факти и податоци, од кои се извлекоа работните хипотези. Потоа, со дедуктивниот пристап движејќи се од општото кон конкретното се тестираат хипотезите и се донесуваат општи заклучоци врз основа на резултатите од експериментите, при што ќе се потврдат или отфрлат хипотезите.

- **Експериментален метод**

За истражување и докажување на поставените хипотези се користи LPBF платформа за адитивно производство на делови од метал. Главата за скенирање на оваа платформа е опремена со коаксијална мониторинг линија, овозможувајќи следење на процесниот зрак во текот на изработката. Спектрометар Avantes 2048 USB2 (Avantes B.V., Апелдорн, Холандија) е имплементиран за коаксијално прибирање на спектралните податоци од зоната на топење за време на експериментите, овозможувајќи мониторинг на интеракцијата помеѓу ласерот и материјалот во реално време. За да се обезбеди собирањето на податоците да започне истовремено со почетокот на ласерската емисија а со тоа кохерентност помеѓу добиениот сигнал и тековниот експериментален процес, аквизицијата на спектрометарот е синхронизирана да започне по иницирањето на ласерската емисија и е овозможена преку доставување на стартен тригер до спектрометарот од контролната картичка на ласерот.

Дополнително, за да се процени кривата на преносливост на оптичкиот ланец на LPBF системот, имплементирана е и конфигурација на мониторинг системот надвор од оптичкиот пат на ласерот, ориентиран под специфичен агол за да набљудува дефиниран регион од интерес над слојот од прав каде што се случува интеракцијата помеѓу ласерот и материјалот.

Во двете конфигурации, спектрометарот е позициониран надвор од комората за печатење, при што коаксијално има поставено оптичко влакно и преку него се доставува процесната емисија до спектрометарот. Дизајнирани се специјализирани стезни прибори за да се обезбеди стабилноста на оптичкото влакно за време на мониторингот, робустно и точно следење на емисијата од процесот, како и за заштита на влакното од потенцијални оштетувања.

За да се одреди кривата на преносливост на оптичкиот пат на ласерот, спроведен е експеримент кој вклучува споредување на спектарот на оптичката емисија добиен со коаксијалната конфигурација на сензорот и оној добиен со конфигурацијата надвор од оптичкиот пат. Единечен ласерски пулс е насочен кон цврста плоча од материјалот AISI316L и неговата процесна емисија е прибрана со двете конфигурации на сензорот. Кривата на преносливост е проценета преку

квантифицирање на разликите и загубите на преносливост поради оптичките компоненти во оптичкиот пат на ласерот. Добиената крива на преносливост потоа се користи во сите експерименти, овозможувајќи трансформација на директните емисии прибрани со коаксијалната поставка во коригирани спектри, со што се обезбедува усогласување на добиените спектрални информации со обработениот материјал.

За да се соберат потребните податоци за анализа и моделирање на споменатите фактори на квалитет користејќи спектрални емисиони информации спроведен е експеримент со SPE ласерска стратегија во LPBF, при што мониторинг е поставен коаксијално во сите експерименти. За да се истражи феноменот на денудација и неговите спектрални карактеристики, експериментите се спроведени користејќи и прав и цврсти форми на истиот тип материјал. Овој пристап овозможува анализа на варијациите во спектралните информации кога има прав наспроти кога нема, симулирајќи ја појавата на денудација. Целосниот факторски експеримент се состои од четири променливи параметри, и секоја комбинација е повторена минимум 3 пати за да резултатот е статистички значаен. Експериментите се спроведени на два типа материјали (AISI316L и Ti-6Al-4V) во две состојби (прашката состојба и полн материјал), а моќноста на ласерот (P) и времето на изложеност на ласерот (t_{on}) се менуваат на три различни нивоа (ниско, средно и високо ниво). Како помошен инертен гас, во сите експерименти се користи аргон со притисок од 1 бар.

- **Статистички (нумерички) метод**


За детална статистичка анализа на собраните експериментални податоци се користи софтверскиот пакет Minitab (Minitab LLC, State College, Пенсилванија, Соединети Американски Држави). Софтверот овозможува испитување на статистичката значајност на променливите фактори врз интензитетите на спектралната емисија преку дисперзиона анализа (ANOVA), графици на влијанијата на факторите врз одзивот на поединечните фактори, како и графици на влијанието на факторите врз одзивот со интеракции за испитување на сложените взаемни дејства помеѓу различните фактори и нивното комбинирано влијание врз резултатите.

- **Метод на истражување со машинско учење** - За емпириско моделирање на истражуваните феномени со машинско учење се користи софтверот MATLAB (The MathWorks Inc., Натик, Масачусетс, Соединети Американски Држави). Корелацијата на спектралните емисиони податоци со обработениот материјал, недостатокот на прав на депонираниот слој и дијаметрите на точките на топење е анализирана со помош на алгоритми за надгледувано машинско учење. За предвидување на типот на материјал и присуството или отсуството на прав користени се методи на машинско учење со класификација, додека методи на машинско учење за регресија се користени за проценка на дијаметарот на точките на топење односно столбот на решеткастата структура. Исто така, за идентификација на

материјалот се применува и анализа на главни компоненти како метод за ненадгледувано машинско учење при што кластерите на материјалот се анализирани со намалување на димензионалноста на влезните податоци од спектралната емисија.

- **Метод на истражување со физички закони** - софтверскиот пакет MATLAB исто така се користи и при анализата со физички теоретски закони за анализа на обликот на термалниот ефект на спектарот со помош на методот на асиметрично измазнување на крива со метод на најмали квадрати, за квалитативна проценка на температурата на црното тело со помош на Виеновиот закон за поместување на зрачењето, и за проценка и квалитативно следење на температурата на електроните во плазмата користејќи го методот на Болцманов график. Потоа дополнителна статистичка анализа на добиените резултати е спроведена во софтверот Minitab.

Методолошката рамка и активностите во истражувањето се прикажани преку дијаграмот на Слика 2.2, кој визуелно ја илустрира логичната последователност на фазите во истражувањето и раздвојувањето на двата методи на анализа на податоците: со примена на машинско учење и со примена на физички закони.



Слика 2.2: Методолошка рамка и активности во докторското истражување

2.5. Придобивки од истражувањето

Истражувањето има потенцијал значително да го унапреди полето на адитивното производство на делови од метал преку примена на машинско учење и оптичка емисиона спектроскопија. Придобивки вклучуваат развој на интелигентни системи за мониторинг на процесот со алгоритми на машинско учење, што ќе овозможи подобрување на квалитетот и прецизноста на производите, како и стекнување на нови знаења за динамиката на процесот. Овие резултати придонесуваат за пошироко прифаќање и примена на адитивното производство во индустријата, вклучувајќи ги секторите на воздухопловство, автомобилската индустрија, биомедицината и енергетиката, каде решеткастите структури се често користени и нивната изработка е возможна исклучиво со адитивно производство.

Врз основа на методите и чекорите кои се спроведени во текот на истражувањето, се добија и потврдија следните резултати:

- Поставен мониторинг систем за оптичка емисиона спектроскопија на LPBF машина за адитивно производство на делови од метал, интегриран коаксијално во оптичкиот ланец на ласерот во главата за скенирање;
- Синхронизирана аквизиција на мониторинг системот со ласерската емисија за да го следи процесот на топење;
- Успешно прибирање на на сигнали од процесот во LPBF со OES мониторинг системот, обезбедувајќи податоци за зоната на топење, каде што обликот на сигналот соодветствува на материјалот што се печати според базата на податоци на Националниот институт за стандарди и технологија (NIST);
- Покажано е дека процесните параметри прават статистички значајни промени врз интензитетот на сигналите;
- Развиена методологија за следење на истражуваните показатели на квалитет и детекција на аномалии во процесот во реално време користејќи сигнали на спектрална емисија и алгоритми за машинско учење;
- Успешно предвидување на материјалот што се печати и појавата на денудација на слојот од прав со машинско учење за класификација, со точност од минимум 85%;
- Успешна проценка на дијаметарот на зоната на топење со машинско учење за регресија, со точност од минимум 85%;
- Успешна проценка на обликот на термалниот ефект на сигналите од спектралната емисија;
- Утврдено е дека зголемувањето на влезот на ласерска енергија ја зголемува температурата на црното тело, демонстрирајќи го влијанието на процесните параметри врз температурата;
- Анализирano и утврдено е влијанието на процесните параметри врз температурата на електроните во плазмата во зоната на топење;
- Покажано е дека со имплементација на OES сензор за мониторинг во реално време и алгоритми за машинско учење се креира интелегентна LPBF машина која е способна да ја следи состојбата на процесот и е свесна за појава на аномалии.
- Потврдување на научно истражувачките хипотези.

2.6. Заклучоци за поглавјето

Прегледот на поставените цели, хипотези и методолошката рамка ја дефинира јасната структура и оригиналноста на ова истражување. Од ова поглавје произлегуваат следните заклучоци:

- Предметот на истражувањето е развој и примена на интелигентен мониторинг систем базиран на оптичка емисиона спектроскопија за следење на процесот на LPBF со SPE стратегија, со интеграција на алгоритми за машинско учење и примена на физички закони за анализа и интерпретација на процесните податоци.
- Поставени се вкупно шест истражувачки цели, секоја со сопствени одделни цели, кои заеднички овозможуваат реализирање на истражувачката идеја и верификација на поставените хипотези.
- Дефинирани се три научно-истражувачки хипотези, кои се логично поставени и поддржани со експериментален план.
- Методологијата на истражувањето се базира на примена на четири научноистражувачки методи (метод на преглед, Индуктивно - дедуктивен метод, експериментален метод, нумерички метод), при што анализата на емисионите спектри е поделена на два начини:
 - Метод 1: Емпириска анализа со примена на алгоритми за машинско учење, насочена кон:
 - проценка на дијаметарот на стопениот регион,
 - детекција на дефект на денудација,
 - препознавање на материјалот што се обработува.
 - Метод 2: Аналитичка анализа со примена на физички закони во спектроскопијата, насочена кон:
 - анализа на обликот на термичката радијација,
 - квалитативна проценка на температурата на „црното тело“,
 - квалитативна проценка на температурата на електроните во плазмата.
- Истражувањето има потенцијал за значителен придонес кон пошироката примена и прифаќање на адитивното производство на делови од метал, особено во секторите на воздухопловство, автомобилска индустрија, биомедицина и енергетика, каде решеткастите структури наоѓаат широка примена.

3. ОСНОВИ НА ПРИМЕНЕТИТЕ МЕТОДИ ВО ИСТРАЖУВАЊЕТО

Согласно заклучочите од анализата на литературата и идентификуваниот фокус на истражувањето со метод на машинско учење и метод на физички закони, во ова поглавје се презентираат основите на кои се темелат применетите методи. Структурата на поглавјето е поделена на два дела: машинско учење и фундаментални физички закони поврзани со спектроскопијата.

Во првиот дел се објаснуваат основните концепти и категории на алгоритми на машинско учење, како и математичката основа на моделите кои се применети во истражувањето за надгледувано учење со класификација и регресија и за ненадгледувано учење со анализа на главни компоненти. Дополнително, дефинирани се метрики за евалуација на моделите кои се користат за проценка на нивната точност.


Вториот дел ги опфаќа физичките основи на спектроскопијата и релевантните закони што се користат во истражувањето, вклучувајќи основи за електронски транзиции, емисиони спектри, температура на црно тело и температура на електрони во плазма.

На овој начин, поглавјето поставува теоретска основа за интердисциплинарниот пристап на истражувањето, каде се интегрираат вештачката интелигенција и физиката во функција на интелигентен мониторинг на LPBF процесот.

3.1. Основи на машинско учење

Машинското учење (МУ) претставува гранка на вештачката интелигенција која се фокусира на развој на алгоритми што можат да учат од податоци и да прават предвидувања или да донесуваат одлуки без експлицитно програмирање [134]. Овој пристап се базира на статистички и нумерички методи за моделирање на зависностите помеѓу влезните податоци (карактеристики) и целните променливи, со цел да се идентификуваат поврзаности и правила во комплексни системи.

За разлика од традиционалното програмирање, каде компјутерот користи однапред дефинирани правила од страна на програмерот за да обработи влезни податоци и да генерира излез, кај машинското учење компјутерот користи влезни и излезни податоци за самостојно да создаде правила од податочното множество без директни инструкции од програмерот (Слика 3.1).




Слика 3.1: Начини на програмирање на компјутер: а) традиционално; б) со машинско учење

Процесот на развој на модел со машинско учење е шематски покажан на Слика 3.2. Тој започнува со прибирање и обработка на податоци, што вклучува пополнување на вредности кои недостасуваат во множеството, отстранување на шум, нормализација, скалирање на податоците за да бидат соодветни за алгоритмот што ќе се користи, и така натаму. Потоа, податоците се делат на податоци за тренирање и податоци за тестирање на моделот.

Во фазата на тренирање односно обучување на моделот, алгоритмот за МУ се тренира со помош на податоците за тренирање и идентификува врски меѓу влезните податоци (карактеристики) и целната променлива. Алгоритмот се вели дека учи од искуство E во однос на некоја задача T и мерка за изведба P , доколку неговата изведба во задачата T , измерена со P , се подобрува со искуство E .

Следен чекор е тестирањето и евалуацијата на моделот. Ова се прави со употреба на помножеството на податоци за тестирање кој што не е користен при тренирањето, со цел да се провери точноста на моделот за предвидување на непознати податоци да се оцени неговата способност за генерализација. Доколку моделот не постигнува задоволителна точност, потребно е калибрирање на моделот што вклучува менување

на хиперпараметрите на моделот, зголемување на податочното множество или повторна обработка на влезните податоци.



Слика 3.2: Процес и фази на развој на модел со машинско учење

Кога моделот ќе постигне задоволителни резултати, тој може да биде имплементиран за реални задачи. Во фазата на користење на моделот со МУ, моделот ги применува научените правила за да предвиди излезни вредности за нови влезни податоци.

Според начинот на кој алгоритмите се тренираат од податоците и ги обучените правила, алгоритмите за машинско учење се делат во три категории: надгледувано учење, ненадгледувано учење и учење со поттикнување [135]. Категориите и нивната последователна поделба се прикажани на шемата дадена на Слика 3.3.


Кај надгледуваното машинско учење, моделот се обучува со користење на означени податоци, каде секој влезен примерок има соодветна излезна вредност. Надгледувањето учење понатаму се дели на два основни типа:

- Регресија – моделот учи да предвидува континуирани нумерички вредности врз основа на зависностите во множеството влезни податоци.
- Класификација – моделот учи да предвидува дискретни вредности, односно класи на податоците.

Ненадгледуваното учење се разликува од надгледуваното по тоа што алгоритмите работат со неозначени податоци, односно влезните податоци немаат однапред дефинирани излезни вредности. Целта е да се идентификуваат релации, структури и сличности во податоците. Постојат два основни типа на ненадгледувано учење:

- Кластерирање – моделот групира слични податоци во кластери врз основа на нивните заеднички карактеристики.

- Намалување на димензионалноста – метод кој има за цел да ја намали комплексноста на влезните податоци преку нивна трансформација во покомпактен простор, при што се задржуваат најрелевантните информации, но со создавање на помал број нови влезни променливи кои се линеарна комбинација од оригиналните. Овој пристап е особено корисен кај податочни множества со голем број на променливи (висока димензионалност), каде што одредени променливи немаат значително влијание врз анализата. Најчесто користена техника за намалување на димензионалноста е анализата на главни компоненти (Principal Component Analysis - PCA).



Слика 3.3: Поделба и категории на машинско учење

Третата категорија на алгоритми со машинско учење е учење со поттикнување, каде моделот учи преку интеракција со околината и добива награди или казни во зависност од тоа дали неговите акции се соодветни или не, согласно поставени правила. Овој метод на МУ е особено ефикасен во динамички средини каде што алгоритмот се прилагодува преку стекнато искуство, како што се автономни работи и стратегии за играње игри.

За целите на докторските истражувања се применети методите на надгледувано учење – регресија и класификација, и на ненадгледувано учење – намалување на димензионалност.

3.2. Алгоритми со машинско учење за класификација


Во оваа секција се дадени теоретските основи и математичките изведувања за методи на машинско учење со класификација кои се применети во истражувањето. Применетите класификациски методи вклучуваат збирни модели како што се моделите со метод на адаптивно засилување и со метод на агрегирање со повеќекратно избирање примероци, како и класични алгоритми како моделот на наивен Бајес, к-најблиски соседи, и машини со носечки вектори.

3.2.1. Збирен модел со метод на засилување за класификација

За да се објасни како функционираат збирните модели со засилување, прво е неопходно да се разгледа основниот концепт на збирните модели и на дрвата на одлучување, бидејќи тие претставуваат основа за изградба на овој тип алгоритми.

Дрвото на одлуки е хиерархиски модел во форма на структура на дрво [136]. Користи серија на правила ако-тогаш, односно прашања со бинарен одговор да/не, кои доведуваат до соодветната класа на влезниот податок. Тренирањето на моделот подразбира последователно учење на правилата за одлучување користејќи ги влезните податоци за учење, со цел да се создаде модел што може да се користи за предвидување на класата на нова променлива. Конечниот модел е дрво кое се состои од јазли за одлучување и листови, прикажан шематски на Слика 3.4. Секој јазол во дрвото претставува прашање или критериум за поделба на податоците, и од него излегуваат две гранки (два одговори) кои зависно од одговорот водат кон следниот јазол. Листот ја претставува предвидената класа. Највисокиот јазол за одлучување што одговара на најдобриот предиктор е наречен корен на дрвото.

Тренирањето на дрвото на одлучување вклучува создавање на структура на дрво преку рекурзивно делење на податоците на подмножества, врз основа на одредени критериуми, со цел да се пронајдат поделби што ја минимизираат „нечистотијата“ или грешката при предвидувањето на секој јазол, што води до подобро разделување на податоците.



Слика 3.4: Шематски приказ на дрво на одлуки со негови составни елементи при машинско учење

За секој јазол за одлучување, се бара најдобриот атрибут j и прагот t за делење на податочното множество D на две подмножества:

$$D_{\text{лево}} = \{x_i \in D: x_{ij} \leq t\} \quad (3-1)$$

$$D_{\text{десно}} = \{x_i \in D: x_{ij} > t\} \quad (3-2)$$

каде што D е тековното множество на податоци во јазолот, x_i е влезниот податок со реден број i , x_{ij} е вредноста на атрибутот j за влезниот податок i .

Квалитетот на делењето се оценува со мерка на хомогеноста или “нечистотијата” на јазолот. Целта на тренирањето на дрво на одлуки е да се најдат најдобрите поделби на податоците што ја минимизираат грешката односно ја максимизираат хомогеноста на излезите во секој јазол. За класификациони задачи, најчесто се користи мерката “Џини нечистотија” (Gini impurity) која се пресметува на следниот начин:

$$G(D) = 1 - \sum_{k=1}^K p_k^2 \quad (3-3)$$

каде што p_k е пропорцијата на податоци во D што припаѓаат на класата k , а K е бројот на класи. За регресиона задача најчесто се користи мерката на средна квадратна грешка (MSE) која се пресметува на следниот начин:

$$MSE(D) = \frac{1}{|D|} \sum_{i=1}^{|D|} (y_i - \hat{y}_i)^2 \quad (3-4)$$

$$MSE(D) = \frac{1}{|D|} \sum_{i=1}^{|D|} (y_i - \hat{y}_i)^2 \quad (3-5)$$

каде што y_i е целната вредност за податокот i , $\hat{y}_i$ е предвидената вредност во D , а $|D|$ е бројот на податоци во D .

За да се избере оптимално делење на јазолот, за секое можно делење (j, t) се пресметува „нечистотијата“ на резултантните подмножества според зададените мерки, каде што функцијата за квалитет на поделбата Q за класификација е дефинирана како:

$$Q(D_{\text{лево}}, D_{\text{десно}}) = \frac{|D_{\text{лево}}|}{|D|} G(D_{\text{лево}}) + \frac{|D_{\text{десно}}|}{|D|} G(D_{\text{десно}}) \quad (3-6)$$

а за регресија како:

$$Q(D_{\text{лево}}, D_{\text{десно}}) = \frac{|D_{\text{лево}}|}{|D|} MSE(D_{\text{лево}}) + \frac{|D_{\text{десно}}|}{|D|} MSE(D_{\text{десно}}) \quad (3-7)$$

Конечно, се усвојува поделбата (j^*, t^*) што што води до најмала „нечистотија“ на јазолот, односно поделбата која најдобро ги раздвојува податоците според нивните класи или вредности, така што подмножествата $D_{\text{лево}}$ и $D_{\text{десно}}$ се со максимална хомогеност:

$$(j^*, t^*) = \arg \min_{j,t} Q(D_{\text{лево}}, D_{\text{десно}}) \quad (3-8)$$

Овој модел е интуитивен, но во многу случаи може да биде слаб, бидејќи единечно дрво на одлучување е подложно на преобучување, односно прекумерно прилагодување на податоците, и може да има висока варијанса. Поради тоа, дрвото на одлучување често се нарекува "слаб" модел или "слаб ученик", но неговата точност во предвидување значително се подобрува кога се комбинира со други дрва во таканаречен збирен модел. Збирен модел претставува техника во машинското учење каде што се комбинираат повеќе слаби модели за да се добие посилен модел со поголема точност и моќ на генерализирање [137]. Основната идеја е дека комбинацијата на повеќе модели може да ја намали варијансата и да ја подобри точноста на предвидувањата, за разлика од кога се користат поединечни модели. Два главни методи за тренинг на збирни модели се методот со засилување [138] и методот на агрегирање со повеќекратно избирање примероци [139]. И двата методи се применети во оваа докторска дисертација, но во оваа секција се објаснува методот со засилување, додека во наредното поглавје (Поглвје 3.2.2) е обработен методот на агрегирање со повеќекратно избирање примероци.

Постојат различни методи на тренирање на збиен модел со засилување за класификација, вклучувајќи адаптивно засилување, засилување на градиентот, екстремно засилување на градиентот, категорично засилување и други варијанти. Разликите меѓу овие методи се во начинот на ажурирање на тежините на влезните податоци по секоја итерација, користењето на методот на намалување на градиентот за оптимизација и во начинот на комбинирање на слабите модели. Во оваа докторска дисертација се користи адаптивно засилување и деталното објаснување за овој метод е даден во продолжение [140].

Кај адаптивното засилување се конструира збиен модел од слаби модели (дрва на одлучување) преку итеративен процес, каде што секој нов слаб модел е трениран на истото множество од податоци, но со модифицирани тежини на примероците, при што поголема тежина добиваат примероците што претходно биле погрешно класифицирани. Тежините на влезните податоци се прилагодуваат така што погрешно класифицираните примероци добиваат поголема тежина, додека точно класифицираните примероци добиваат помала тежина [141]. На овој начин, новите слаби модели учат да ги исправат грешките на претходните модели/ученици.

За формална математичка изведба на алгоритамот, дадено е множеството за тренирање:

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (3-9)$$

каде што x_i претставува множество на влезни податоци, $y_i \in \{-1, +1\}$ е класата на секој пример, а n е бројот на податоци во множеството за тренирање.

Адаптивното засилување доделува тежина на секој примерок за тренирање со цел да ја одреди неговата важност во фазата на тренирање на моделот. Кога доделените тежини се високи, тие примероци имаат поголемо влијание во процесот на тренирање. Слично, кога тежините се ниски, нивното влијание во множеството за тренирање е минимално.

При иницијализација на вредноста на тежините, сите податоци имаат еднаква тежинска вредност w :

$$w_i^{(1)} = \frac{1}{n}, \quad i = 1, 2, \dots, n \quad (3-10)$$

каде $w_i^{(t)}$ е тежината на податокот i на итерацијата t , при што $t = 1, 2, \dots, T$, каде T е бројот на слаби модели (дрва на одлучување) кои во случај на класификација се нарекуваат уште и слаби класификатори. При тренирањето на моделот, во секоја итерација t се тренира слаб класификатор $h_t(x)$ со множеството за тренирање, земајќи ги предвид тежините $w_i^{(t)}$.

Потоа се пресметува вкупната тежина на погрешно класифицираните податоци ε_t (грешката според зададените тежини) која е дефинирана како:

$$\varepsilon_t = \sum_{i=1}^n w_i^{(t)} I(h_t(x_i) \neq y_i) \quad (3-11)$$

каде што $I(\cdot)$ е индикаторска функција која враќа 1 ако класификаторот погрешно го класифицирал примерокот, а 0 ако го класифицирал точно.

Тежината на секој слаб класификатор $h_t(x)$ се дефинира преку неговата тежинска вредност α_t која се пресметува според следната равенка:

$$\alpha_t = \frac{1}{2} \ln \left(\frac{1 - \varepsilon_t}{\varepsilon_t} \right) \quad (3-12)$$

Доколку класификаторот е подобар од случајното претпоставување тогаш α_t е позитивно, а ако е полош α_t е негативно (во пракса, таков класификатор најчесто се отфрла).

Во секоја наредна итерација $t + 1$, односно при тренирањето на секој нареден слаб класификатор, тежините на податоците се ажурираат така што погрешно класифицираните примероци добиваат поголема тежина според следната равенка:


$$w_i^{(t+1)} = w_i^{(t)} \cdot \exp(-\alpha_t y_i h_t(x_i)) \quad (3-13)$$

Тежините се нормализираат за нивната сума да биде еднаква на 1 и потоа се користат за следната итерација. По завршувањето на фазата на учење, односно после T итерации, конечниот модел се изразува како збир на слабите класификатори, каде што одлуката се носи врз основа на знакот (што кореспондира со класата) на збирот на нивните излезна предвидувања, скалирани со соодветните тежински вредности:

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right) \quad (3-14)$$

каде што T е вкупниот број на слаби класификатори, α_t е тежината на t -тиот слаб класификатор која го одразува неговиот релативен придонес во конечниот модел, а $h_t(x)$ е предвидувањето на t -тиот слаб класификатор за влезниот податок x .

Овој метод овозможува моделот да биде адаптивен, бидејќи секој нов слаб класификатор учи од грешките на претходните, подобрувајќи ја целокупната точност. Шематски збирниот модел со адаптивно засилување е претставен на Слика 3.5.



Слика 3.5: Шематски приказ на принципот на работа збиен модел со метод на адаптивно засилување

3.2.2. Збиен модел со метод на агрегирање за класификација

Методот на агрегирање со повеќекратно избирање примероци е збиен модел во машинското учење каде главната идеја е да се создадат повеќе слаби модели во кои влезните податоци ќе бидат примероци (подмножества) од множеството за тренирање, и потоа нивните предвидувања се комбинираат за да се добие финалниот излез [139]. Кај овој метод податоците во влезните примероци за секој слаб модел се избираат произволно и истите можат повеќекратно да се повторуваат, што значи дека одредени податоци може да се појават повеќе пати во едно подмножество, додека други може сосема да изостанат. Овој метод се разликува од методот на учење со засилување по тоа што сите слаби модели се тренираат паралелно и независно еден од друг.

Секој податок има приближно 63% шанса да биде избран во примерокот за тренирање со повеќекратно избирање примероци, бидејќи при секоја итерација на земање примероци веројатноста податокот да не биде избран е $1 - \frac{1}{N}$. Кога овој процес се повторува N -пати, веројатноста податокот да не биде избран ни еднаш е

$(1 - \frac{1}{N})^N$, што за големи вредности на N се доближува до $\frac{1}{e}$. Затоа, веројатноста податокот да биде избран барем еднаш е $1 - \frac{1}{e}$, што е приближно 0.63 или 63%.

За да математички се формулира алгоритмот, нека е дадено множеството за тренирање:

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\} \quad (3-15)$$

каде x е вектор од влезните податоци, y е вектор на целните излезни променливи кои моделот треба да научи да ги предвидува (за задачи на класификација е категорична променлива), а N е бројот на податоци во множеството на тренирање.


Потоа се креираат примероците за тренирање D_b , при што повеќекратно избирање примероци се прави B пати за да се креираат B различни примероци за тренирање:

$$D_b = \{(x_{i_1}, y_{i_1}), (x_{i_2}, y_{i_2}), \dots, (x_{i_N}, y_{i_N})\}, \quad b = 1, 2, \dots, B \quad (3-16)$$

каде што i_j се индекси на случајно избрани податоци од оригиналното множество D . Секој примерок за тренирање D_b се користи за тренирање на одделен слаб класификатор $h_b(x)$, односно одделен модел на дрво на одлучување. Финалниот излез се добива преку мнозинско гласање кое ги агрегира предвидувањата од сите слаби класификатори:

$$H(x) = \underset{y}{\operatorname{argmax}} \sum_{b=1}^B I(h_b(x) = y) \quad (3-17)$$

каде што $I(\cdot)$ е индикаторска функција што враќа 1 ако предвидувањето на моделот $h_b(x)$ е еднакво на класата y , инаку враќа 0; а $\underset{y}{\operatorname{argmax}}$ ја избира класата y со најголем број гласови. Финалната предвидена класа за влезниот податок x е онаа која има најголем број гласови од страна на сите класификатори во збирниот модел. Шематски збирниот модел со повеќекратно избирање примероци е претставен на Слика 3.6.



Слика 3.6: Шематски приказ на принципот на работа на збирен модел со метод на агрегирање со повеќекратно избирање примероци

3.2.3. Бајесов наивен алгоритам

Бајесовиот наивен алгоритам е алгоритам за надгледувано машинско учење, кој се заснова на Бајесовата теорема и се користи за решавање на проблеми со класификација [142]. Тој е класификатор базиран на теорија на веројатност и се користи за пресметување на веројатноста за класата врз основа на познатите податоци од множеството за тренирање. Основната претпоставка на Бајесовиот наивен класификаторот е дека влезните променливи се меѓусебно независни, и дека секоја влезна променлива дава независен и еднаков придонес кон излезната променлива, односно на секоја влезна променлива се дава еднаква тежина врз придонесот на излезот.

Во фазата на тренирање, алгоритамот ги анализира податоците за да ја процени веројатноста на секоја класа и веројатностите на секоја влезна променлива во однос на класите. Во фазата на предвидување, кога се внесуваат нови податоци, алгоритамот ги пресметува веројатностите за секој податок да припаѓа на секоја од можните класи и ја одредува класата со највисока веројатност како финален избор.

Бајесовиот наивен алгоритам за класификација се базира на теоремата на Бајес која се формулира со следната равенка:

$$P(y|X) = \frac{P(X|y)P(y)}{P(X)} \quad (3-18)$$

каде што X се влезните податоци а y е класата, и $P(y) \neq 0$.

$P(y|X)$ е веројатноста дека дадениот вектор на влезни податоци X припаѓа на класата y (постериорна веројатност, или уште позната како условна веројатност). $P(X|y)$ е веројатноста да се добие векторот од влезни податоци X , кога ќе се случи класата y ("обратна" условна веројатност). $P(X)$ и $P(y)$ се веројатностите да настаните X и y се случат независно без зададени услови (априорна веројатност), каде што $P(y)$ е априорна веројатност за класата y и е позната од податоцитза тренирање, а $P(X)$ е општата веројатност за податоците и се игнорира при споредба.

Бидејќи влезните податоци во ова истражување се континуирани, користен е алгоритмот Гаусов наивен Бајес [143], кој претпоставува дека "обратната" условна веројатност $P(x_i|y)$ за секој податок x_i и класа y следи Гаусова распределба, односно:

$$P(x_i|y) = \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \quad (3-19)$$

каде што:

- x_i : Вредност на променливата што се анализира,
- μ_y : Средна вредност на променливата x_i за класата y ,
- σ_y^2 : Варијанса на променливата x_i за класата y .

Веројатноста $P(X|y)$ претставува веројатност дека целиот вектор од влезни податоци $X = \{x_1, x_2, \dots, x_n\}$ ќе се појави, под услов дека векторот припаѓа на одредена класа y . Според претпоставката на Наивниот Бајес за независност на променливите, веројатноста за целиот вектор X може да се пресмета како производ на веројатностите за секоја поединечна променлива x_i , условена од класата y . Ова се изразува како:

$$P(X|y) = \prod_{i=1}^n P(x_i|y) \quad (3-20)$$

Со примена на функцијата за Гаусовата распределба (равенка (3-19)), равенката (3-20) се проширува во следниот облик:

$$P(X|y) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_i - \mu_y)^2}{2\sigma_y^2}\right) \quad (3-21)$$

Постериорната веројатност е пропорционална на производот од априорната веројатност и условната веројатност:

$$P(y|X) \propto P(y)P(X|y) \quad (3-22)$$

Со примена на равенка (3-21) во равенка (3-22), постериорната веројатност ја добива следната форма:

$$P(y|X) \propto P(y) \prod_{l=1}^n \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_l - \mu_y)^2}{2\sigma_y^2}\right) \quad (3-23)$$

Предвидената класа $y_{\text{предвидено}}$ се одредува како онаа класа која има највисока апостериорна веројатност:

$$y_{\text{предвидено}} = \arg \max_y \left[P(y) \prod_{l=1}^n \frac{1}{\sqrt{2\pi\sigma_y^2}} \exp\left(-\frac{(x_l - \mu_y)^2}{2\sigma_y^2}\right) \right] \quad (3-24)$$

Оттука, крајната одлука на алгоритмот е да го класифицира влезниот податок во класата y , за која $P(y|X)$ има максимална вредност, односно алгоритмот ја избира класата y што ја максимизира апостериорната веројатност врз основа на достапните податоци X .

3.2.4. Алгоритам k -најблиски соседи

Основниот принцип на алгоритмот k -најблиски соседи за класификација се заснова на споредба на влезните податоци со нивните најблиски соседи во множеството со податоци, врз основа на метрика за растојание [144]. k -најблиски соседи е непараметарски алгоритам, што значи дека не претпоставува никаква претходно дефинирана распределба на податоците. Тој го користи целото множество за тренирање при донесување на одлуки, без да тренира експлицитен модел. Основната идеја е дека податоците со слични карактеристики ќе бидат на мало растојание во просторот на карактеристиките.

Математички, алгоритмот k -најблиски соседи се формулира на следниот начин. Прво, се дефинира множеството од k -те најблиски соседи на точката x , означено како R_x . Множеството R_x е подмножество на множеството за тренирање S , каде што бројот на елементи во множеството R_x е еднаков на k , и $\forall (x', y') \in S \setminus R_x$ важи дека:

$$\text{dist}(x, x') \geq \max_{(x'', y'') \in R_x} \text{dist}(x, x'') \quad (3-25)$$

Ова значи дека за секоја точка (x', y') која припаѓа на S но не припаѓа на R_x , растојанието помеѓу x и x' мора да биде поголемо или еднакво на најголемото растојание помеѓу x и било која друга точка x'' која припаѓа во R_x [145]. На овој начин, R_x ги содржи k -те точки што се најблиски до x .

Кога множеството R_x е дефинирано, класата $y_{\text{предвидено}}(x)$ на новиот влез x се одредува како класата што најчесто се појавува во R_x , односно:


$$y_{\text{предвидено}}(x) = \text{mode}(\{y'' : (x'', y'') \in R_x\}) \quad (3-26)$$

што значи дека предвидената класа $y_{\text{предвидено}}(x)$ се определува како најчесто појавуваната класа y'' од податоците (x'', y'') што припаѓаат на множеството R_x .

Може да се користат различни метрики за пресметување на растојанието помеѓу податоците, но во ова истражување е применета Евклидовата метрика како метрика која даде најточни резултати за истражуваниот проблем. Равенката за пресметување на растојанието помеѓу две точки x_i и x'_i според Евклидовата метрика е следната:

$$\text{dist}(x, x')' = \sqrt{\sum_{i=1}^n (x_i - x'_i)^2} \quad (3-27)$$

Точноста на алгоритмот зависи од правилниот избор на бројот на соседи k и од избраната метрика за растојание [146], кои подоцна се оптимизираат при објаснувањето на неговата имплементација. Визуелизација на принципот на работа на алгоритмот k -најблиски соседи е дадена на Слика 3.7.



Слика 3.7: Шематски приказ на принципот на работа на алгоритмот k -најблиски соседи за $k = 3$

3.2.5. Машини со носечки вектори


Машините со носечки вектори претставуваат надгледуван алгоритам за машинско учење, кој се заснова на принципот на пронаоѓање на оптимална хипер-рамнина, која ги одделува класите во просторот на карактеристики на начин што ја максимизира маргината меѓу нив [147]. Алгоритамот на машини со носечки вектори ги претставува влезните податоци за тренирање како точки во просторот, при што секоја точка е означена со класата на која ѝ припаѓа. За подобра визуелизација на овој концепт, на Слика 3.8 а) е прикажан пример со две класи и два влезни параметри (x_1 и x_2), каде се дадени три можни хипер-рамнини (R1, R2 и R3). Сепак, постојат бесконечно многу можни хипер-рамнини кои можат да ги разделат податоците. За да се одреди оптималната хипер-рамнина, основниот принцип на машините со носечки вектори е максимизирање на маргината, односно најмалото растојание помеѓу хипер-рамнината и најблиските точки од секоја класа. Оваа маргина е прикажана на Слика 3.8 б). Со зголемување на маргината, се минимизира ризикот од погрешна класификација и се подобрува способноста за генерализација на моделот. Според тоа, од прикажаните хипер-рамнини на Слика 3.8 а) може да се согледа дека хипер-рамнината R1 најефикасно ги одвојува двете класи бидејќи има максимална маргина, додека хипер-рамнината R3 иако успешно ги одвојува двете класи сепак е со помала маргина што значи дека не е оптималниот избор.

Податочните точки што лежат на или најблиску до границите на маргината се нарекуваат носечки вектори (види Слика 3.8 б), бидејќи тие ја дефинираат позицијата на оптималната хиперрамнина и имаат директно влијание врз процесот на класификација. Алгоритамот ги користи исклучиво носечките вектори за да ја формулира конечната одлука за класификација, наместо да се потпира на сите податоци во множеството на податоци за тренирање. Ова го прави ефикасен и робустен модел, особено при анализа на високо-димензионални множества на податоци, односно податоци кои имаат голем број на влезни карактеристики (фактори).

Во n -димензионален простор, хипер-рамнината е $(n - 1)$ -димензионален подпростор кој ги дели податоците на две класи. Формално, хипер-рамнината може да се претстави како:

$$w^T x + b = 0 \quad (3-28)$$

каде што w е вектор на тежини, x е вектор на влезни карактеристики, а b е компензација.



Слика 3.8: Пример со две класи и два влезни параметри (x_1 и x_2): а) три можни хипер-рамнини (R1, R2, R3) за раздвојување на класите; б) дефинирање на носечки вектори и принцип на работа на машините со носечки вектори, каде се одбира оптимална хипер-рамнина преку максимизирање на маргините

За дадено множество со податоци за тренирање $\{(x_i, y_i)\}_{i=1}^N$, со број на податоци еднаков на N , каде што $x_i \in \mathbb{R}^n$ и $y_i \in \{-1, +1\}$, x_i претставува вектор на влезни карактеристики за податокот за тренирање со реден број i , а y_i е соодветна ознака на класата.

Кога со машината со носечки вектори се решава линеарен проблем, целта е да се најде хипер-рамнина што ја максимизира маргината M која ги разделува класите, која е дефинирана како:

$$M = \frac{2}{\|w\|} \quad (3-29)$$

Ова се формулира како следната оптимизациона равенка која треба да се реши при тренирањето на моделот:

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (3-30)$$

Условот кој треба да биде исполнет за сите податоци i да лежат на или надвор од границите на маргината е следниот:

$$y_i(w^T x_i + b) \geq 1, \quad \forall i = 1, \dots, N \quad (3-31)$$

Ова се нарекува модел на машина со носечки вектори со таканаречена тврда маргина.


Ако податоците не се идеално разделливи, се воведуваат релаксациски променливи ξ_i за да се дозволат одредени грешки, што води до машина со носечки вектори со мека маргина [148], кај која оптимизационата равенка која се решава го добива следниот облик:

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (3-32)$$

под услов:

$$y_i(w^T x_i + b) \geq 1 - \varepsilon_i, \varepsilon_i \geq 0 \forall i \quad (3-33)$$


каде што C е регулационен параметар кој го контролира балансот меѓу максимизирање на маргината и минимизирање на грешките. Споредба помеѓу дефинираните хипер-рамнини во зависност од дали е користена тврда или мека маргина во моделот е прикажана на Слика 3.9.



Слика 3.9: Споредба на дефинирањето на хипер-рамнина кај машините со носечки вектори во зависност од примената на тврда или мека маргина

Вредноста на C ја одредува јачината на казната за грешките при класификацијата на податоците, односно колку строго моделот ќе се обиде да ги избегне грешките во процесот на тренирање на моделот [149]. Поголеми вредности на C го принудуваат моделот да ги минимизира грешките во податоците за тренирање, со што создава помала маргина која максимално ги раздвојува класите. Сепак, ова може да доведе до прекумерно прилагодување на податоците, бидејќи моделот може да стане

премногу специфичен за податоците за тренирање и да не може да ги обработи новите податоци. Од друга страна, помалите вредности на C дозволуваат поголема флексибилност и толеранција за грешки во податоците за тренирање, што резултира со поголема маргина кој има подобра способност за генерализација, но премали вредност на C можат да доведат до погрешно класифицирање и мала точност на моделот. Влијанието на параметарот C врз дефинирањето на маргините и позицијата на хипер-рамнината е илустрирано на Слика 3.10.



Слика 3.10: Влијанието на вредноста на параметарот C врз дефинирањето на маргините и позицијата на хипер-рамнината кај машините со носечки вектори

Бидејќи решавањето на дефинираната оптимизациона равенка вклучува ограничувања и зависи директно од бројот на параметри w (кој пак зависи од бројот на влезни карактеристики), тешко е да се реши со класични оптимизациски техники. Заради таа причина при решавањето на оптимизацискиот проблем кај машините со носечки вектори се користи Лагранжов пристап со Лагранжови множители [150], при што се воведуваат множители α_i за секое ограничување $y_i(w^T x_i + b) - 1 \geq 0$ и се формира Лагранжовата функција со следниот облик:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i [y_i(w^T x_i + b) - 1] \quad (3-34)$$

По елиминирањето на w и b , се добива нова оптимизациска равенка, која зависи само од Лагранжовите множители α_i :

$$\max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i^T x_j) \quad (3-35)$$

под услов:

$$\sum_{i=1}^N \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq C, \quad \forall i \quad (3-36)$$


Првата сума ($\sum_{i=1}^N \alpha_i$) ги сумира сите Лагранжови множители α_i за секоја податочна точка i . Втората двојна сума ($\sum_{i=1}^N \sum_{j=1}^N$) ги разгледува сите можни парови на податочни точки (i, j) , каде што нивните множители α_i и α_j , ознаките за класа y_i и y_j , и сличноста $x_i^T x_j$ придонесуваат за оптимизацијата.

Овој пристап на решение на таканаречениот “дуален” проблем кај машините со носечки вектори е побрз и поефикасен бидејќи зависи од бројот на податоци, а не од димензијата на податоците, што е корисно во ова истражување. Понатаму ќе биде објаснето дека димензијата на податоците (односно бројот на карактеристики/фактори) е поголема од бројот на податоците кои се користат во ова истражување. Кога ќе се реши дуалниот проблем, оние податоци за тренирање на моделот кои имаат $\alpha_i > 0$ се носечки вектори и тие ја дефинираат хипер-рамнината.

Кога податоците не се линеарно разделиви со хипер-рамнина во нивниот оригинален простор, машината со носечки вектори користи таканаречени “кернел” функции, со кои се мапираат податоците во повисоко-димензионален простор каде што тие стануваат линеарно разделиви [151]. Кернел функцијата $K(x_i, x_j)$ го пресметува скаларниот производ помеѓу точките во трансформираниот простор без експлицитно да ја изврши трансформацијата $\phi(x)$, на следниот начин:

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (3-37)$$

што значително ја намалува компјутерската сложеност. На Слика 3.11 е прикажана визуелна демонстрација на имплементацијата на кернел функција за одделување на две класи, каде оригиналниот простор на податоците се трансформира во повисоко-димензионален простор. Оваа трансформација овозможува зголемување на растојанието помеѓу податоците што припаѓаат на двете различни класи, со помош на соодветна математичка кернел функција. По трансформацијата, целта останува иста - да се пронајде оптимална хипер-рамнина која ги разделува класите, но овој пат во новиот, повисоко-димензионален простор, каде податоците стануваат линеарно разделливи.



Слика 3.11: Демонстрација на имплементацијата на кернел функција за одделување на две класи со хипер-рамнина, каде оригиналниот простор на податоците се трансформира во повисоко- димензионален простор – слика адаптирана од [152]

Потоа, дуалниот проблем се модифицира со замена на $x_i^T x_j$ со кернел-функција и оптимизациската равенка го добива следниот облик:

$$\max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (3-38)$$

За подобро разбирање на најчесто користените кернел фунцкии како и приказ на нивните равенки, деталите се дадени во Табела 3-1 [151].

Откако ќе се реши дуалниот проблем, хипер-рамнината кај моделот со носечки вектори е дадена со следната равенка:

$$w = \sum_{i=1}^m \alpha_i y_i K(x_i, x) + b \quad (3-39)$$

Вредноста на компензацијата b се определува врз основа на носечките вектори (x_i), при што важи:

$$y_i (w^T x_i - b) = 1 \quad \Rightarrow \quad b = w^T x_i - y_i \quad (3-40)$$

Кога моделот е обучен, предвидената класа $\hat{y}$ за новиот влез x се предвидува со изразот:

$$\hat{y} = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i K(x_i, x) + b \right) \quad (3-41)$$

Зависно од добиениот знак пред вредноста, равенката пресметува дали влезниот податок x се наоѓа на позитивната или негативната страна на хипер-рамнината, со што се определува неговата класа.

Табела 3-1: Најчесто користени кернел функции кај машините со носечки вектори [151]

Кернел функција	Равенка	Опис	Примена
Линеарен кернел	$K(x_i, x_j) = x_i^T x_j$	Линеарен скаларен производ; го користи оригиналниот простор без трансформации.	Кога податоците се линеарно разделливи без трансформација.
Полиномен кернел	$K(x_i, x_j) = (x_i^T x_j + c)^d$	Мапира податоци во полиномен простор. d е степенот на полиномот, c е константа.	За нелинеарни односи со пониски димензии.
Кернел со радијална основа	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$	Мапира податоци во бесконечно-димензионален простор со употреба на Гаусова функција.	Кога границите меѓу класите се комплексни и нелинеарни.
Кернел на основа на растојание	$K(x_i, x_j) = f(\ x_i - x_j\)$	Произволна функција која зависи од растојанието меѓу точките.	За задачи каде што растојанието носи значајни информации за класификација.

3.3. Алгоритми со машинско учење за регресија

Во наредниот дел се изведени теоретските основи и математичката формулација за регресионите модели што се користени во ова истражување. Детално се разгледани моделот на регресија со Гаусов процес, регресијата со носечки вектори, збирните модели со засилување со метод на најмали квадрати и со метод базиран на агрегирање со повеќекратно избирање примероци за регресија, како и вештачките невронски мрежи.

3.3.1. Модел на регресија со Гаусов процес

Моделот на регресија со Гаусов процес претставува метод со машинско учење за регресија кој се базира на Гаусов процес кој е збир од случајни променливи, при што кое било конечно подмножество од случајни променливи, разгледувано како случаен вектор, има повеќедимензионална нормална распределба [153]. Со други зборови, за секој збир на точки $x_1, x_2, \dots, x_n$, соодветните вредности на функцијата $f(x_1), f(x_2), \dots, f(x_n)$ се распределени според мултиваријантна нормална распределба. Овој алгоритам ја користи оваа особина за да моделира функција $f(x)$, која го поврзува влезот x со излезот y , под претпоставка дека:


$$y = f(x) + \epsilon \quad (3-42)$$

каде што $f(x)$ е функцијата која се моделира како Гаусов процес, а ϵ е шум, кој се смета дека следи нормална распределба $\epsilon \sim \mathcal{N}(0, \sigma^2)$.

Функцијата $f(x)$ се моделира како случаен процес со следнава Гаусова распределба:

$$f(x) \sim \mathcal{GP}(m(x), k(x, x')) \quad (3-43)$$

каде што $m(x)$ е функцијата за средна вредност, која претставува очекуваната вредност на $f(x)$, а $k(x, x')$ е функцијата за коваријанса која ја мери сличноста помеѓу две точки x и x' . Наместо да претпоставува специфична форма на функцијата, алгоритмот ја третира функцијата како случаен процес, дефиниран преку функција на средна вредност и функција на коваријанса која се опишува преку кернел функција. Функцијата на средна вредност го претставува очекуваниот тренд на функцијата, додека коваријансната функција го мери степенот на сличност помеѓу различни точки, што е важна предност затоа што се овозможува способност за моделирање на нелинеарни односи. Дополнителна предност на овој алгоритам е што не само што ја предвидува вредноста туку исто така дава и мерка на стандардната девијација на предвидувањето, што го прави особено корисен за моделирање на податоци со шумови. Конечно, моделот овозможува екстраполација на предвидувањата во области од параметарскиот простор каде што нема достапни податоци за тренирање. Овие три својства се илустрирани на Слика 3.12 за мултимодална тест-функција со шум.



Слика 3.12: Влијание на бројот на податоци за тренирање врз точноста и интервалот на доверба на моделот на регресија со Гаусов процес

Во моделот на регресија со Гаусов процес, честопати се претпоставува дека функцијата за средна вредност $m(x)$ е еднаква на нула за поедноставување на моделот без губење на способноста за генерализација. Оваа претпоставка е оправдана бидејќи функцијата за коваријанса $k(x, x')$ ги опишува релациите и структурата на податоците, додека средната вредност може да се отстрани преку претходна обработка на податоците (центрирање). Ако е познато дека $m(x)$ не е нула, таа може експлицитно да се дефинира или да се моделира соодветно.

За дадено множество на n податоци за тренирање $\{x_i, y_i\}_{i=1}^n$, функцијата $f(x)$ следи мултиваријантна нормална распределба со средна вредност $m(x)$ и коваријансна матрица K (со големина $n \times n$), каде што:

$$K[i, j] = k(x_i, x_j) \quad (3-44)$$

За да се прикаже предвидувањето на вредноста на $f(x_*)$ за нов влез x_* , дадено е множество на податоци за тренирање (X, y) , каде што X е матрица од влезни податоци и y е векторот на излезни вредности. Заедничката распределба на излезните вредности помеѓу набљудуваните целни вредности y и вредностите на функцијата $f(x_*)$ е:

$$\begin{bmatrix} y \\ f(x_*) \end{bmatrix} \sim \mathcal{N} \left(0, \begin{bmatrix} K(X, X) + \sigma^2 I & K(X, x_*) \\ K(x_*, X) & K(x_*, x_*) \end{bmatrix} \right) \quad (3-45)$$

каде:

- $y = [y_1, y_2, \dots, y_n]^T$ е векторот на излезни вредности,
- $K(X, X)$ е матрицата на коваријанса помеѓу податоците за тренирање со елементи $k(x_i, x_j)$,

- $K(X, x_*)$ е векторот на коваријанси помеѓу податоците за тренирање и новиот податок x_* ,
- $K(x_*, x_*)$ е коваријансата на новиот податок со самиот себе,
- σ^2 е стандардната девијација на шумот,
- I е единечна матрица.

Со примена на својствата на повеќедимензионалната нормална распределба се добива равенката за предвидување со регресија со Гаусов процес:

$$f_*|X, y, x_* \sim \mathcal{N}(\bar{f}_*, \text{cov}(f_*)) \quad (3-46)$$

каде што средната предвидена вредност за x_* и стандардната девијација на предвидувањето за x_* се дадени со:

$$\mu(x_*) = K(x_*, X)[K(X, X) + \sigma^2 I]^{-1} y \quad (3-47)$$

$$\sigma^2(x_*) = K(x_*, x_*) - K(x_*, X)[K(X, X) + \sigma^2 I]^{-1} K(X, x_*) \quad (3-48)$$

Кернел функциите $k(x, x')$ ја определуваат коваријансата помеѓу две точки x и x' . Ова овозможува да се опише начинот на кој функцијата $f(x)$ се менува низ просторот на влезните податоци. Кога влезните податоци не се линеарно распоредени, кернел функциите го трансформираат просторот на податоците во повисок димензионален простор каде што функцијата може да се моделира линеарно, при што со избор на соодветна кернел функција моделот може да се прилагоди за различни типови на податоци и задачи [154]. Табела 3-2 ги сумира најчесто применетите кернел функции при моделирање на регресија со Гаусов процес [154].

Табела 3-2: Најчесто користени кернел функции кај моделот на регресија со Гаусов процес [154]

Кернел функција	Равенка
Кернел функција со радијална основа	$k(x, x') = \sigma^2 \exp\left(-\frac{\ x - x'\ ^2}{2l^2}\right)$
Матерн кернел	$k(x, x') = \sigma^2 \frac{2^{1-v}}{\Gamma(v)} \left(\frac{\sqrt{2v}\ x - x'\ }{l}\right)^v K_v\left(\frac{\sqrt{2v}\ x - x'\ }{l}\right)$
Рационален квадратен кернел	$k(x, x') = \sigma^2 \left(1 + \frac{\ x - x'\ ^2}{2\alpha l^2}\right)^{-\alpha}$
Експоненцијално-синусен кернел	$k(x_i, x_j) = \exp\left(-\frac{2\sin^2(\pi d(x, x')/p)}{l^2}\right)$
Кернел со производ	$k(x, x') = x \cdot x'$

3.3.2. Регресија со носечки вектори

Моделот за регресија со носечки вектори е проширување на алгоритмот за машини со носечки вектори што се користи за решавање на задачи на регресија наместо класификација. Основната идеја зад овој алгоритам е да се најде оптималната функција што најдобро го опишува континуираниот излез, додека ги минимизира грешките во рамките на дефинирана толеранција (ε) [155]. Односно, кај моделот за регресија со носечки вектори наместо да се најде хипер-рамнина што ги одделува класите како во моделот за класификација, алгоритмот се стреми да најде хипер-рамнина $f(x)$ која ги предвидува излезните вредности со најмала можна грешка, додека дозволува отстапувања во рамките на толеранцијата ε . ε -толерантната зона го дефинира интервалот околу функцијата на регресија $f(x)$, во кој предвидувањата се сметаат за точни. Тоа значи дека ако разликата помеѓу предвидената вредност $f(x)$ и вистинската вредност y е помала или еднаква на ε , тогаш нема казна при моделирањето (грешката се игнорира). Грешките надвор од опсегот дефиниран со ε се казнуваат преку оптимизациски процес во фазата на тренирање на моделот.

За дадено множество на влезни податоци x_i со соодветни излезни вредности y_i , овој алгоритам настојува да ја пронајде функцијата:

$$f(x) = w^T \phi(x) + b \quad (3-49)$$

каде што w е вектор на тежини, $\phi(x)$ е функција за трансформација на податоците во повисока димензија преку кернел функции, а b е компензација. Оваа функција треба да биде што е можно поблиску до реалните вредности y_i , но без да ги казнува точките што се во рамките на дозволената толеранција ε . Како и при моделирањето за класификација со носечки вектори, и тука се користи кернелот за да се трансформираат податоците во повисока димензија, каде што сложените и нелинеарни односи меѓу нив стануваат линеарно решливи преку оптимизацискиот процес. Така што оптималната хипер-рамнина во трансформираниот простор ја дефинира регресионата равенка $f(x)$ која треба да се најде при тренирањето на моделот.

Целта на моделот е да го минимизира тежинскиот вектор w за да се добие оптималната функција, при тоа задоволувајќи го условот дека предвидувањата се во рамките на ε -толерантната зона. Ова се формулира како следниот оптимизациски проблем:

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3-50)$$

под услов:

$$y_i - (w^T \phi(x_i) + b) \leq \varepsilon + \xi_i \quad (3-51)$$


$$(w^T \phi(x_i) + b) - y_i \leq \varepsilon + \xi_i^* \quad (3-52)$$

$$\xi_i, \xi_i^* \geq 0, \quad i = 1, \dots, n$$

каде што:

- ε ја дефинира зоната на толеранција во која предвидените вредности може да отстапуваат без да бидат казнети,
- ξ_i и ξ_i^* се променливи кои ја моделираат грешката надвор од ε , при што ξ_i е за позитивно отстапување а ξ_i^* за негативно,
- C е параметар кој го контролира компромисот меѓу сложеноста на моделот и толеранцијата на грешки, за кој е детално објаснето во Поглавјето 3.2.5. и демонстрирано на Слика 3.10.

Слика 3.13 дава приказ за дефинирањето на хипер-рамнината, зоната на толеранција со параметарот ε , и параметрите ξ_i и ξ_i^* .



Слика 3.13: Дефинирање на хипер-рамнината и зоната на толеранција кај моделот за регресија со носечки вектори

И кај моделот за регресија со носечки вектор се користи пристапот на решение во “дуална” форма, односно се користи Лагранжовиот пристап со Лагранжови множители. Со тоа се трансформира оригиналниот оптимизациски проблем во поедноставен облик, кој зависи само од податоците за тренирање и кернел функцијата, со што се овозможува пресметување на решението без експлицитно пресликување во повисока димензија. Дуалната форма на овој модел ја добива следната форма:

$$\max_{\alpha, \alpha^*} \left(-\frac{1}{2} \sum_{i,j} (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) + \sum_i (\alpha_i - \alpha_i^*) y_i - \varepsilon \sum_i (\alpha_i + \alpha_i^*) \right) \quad (3-53)$$

под услов:

$$\sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0; \quad \alpha_i, \alpha_i^* \in [0, C] \quad (3-54)$$

каде што:

- $K(x_i, x_j)$ е кернел функцијата што го пресметува скаларниот производ во трансформираниот простор $\Phi(x)$, без експлицитна трансформација (равенка (3-37)),
- α_i и α_i^* се Лагранжови множители што го дефинираат влијанието на секој податок во моделот.

Откако моделот е истрениран, предвидувањето за нов податок x_* се изведува преку функцијата:

$$f(x_*) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x_i, x_*) + b \quad (3-55)$$

каде што:

- $K(x_i, x_*)$ е кернел функцијата помеѓу новиот податок x_* и носечките вектори x_i ,
- α_i, α_i^* се Лагранжовите множители за носечките вектори,
- b е компензацијата што се пресметува од носечките вектори.

Само носечките вектори, односно податоците што имаат $\alpha_i > 0$, придонесуваат за предвидувањето, што го прави овој метод ефикасен и моќен за работа со големи множества податоци.


Основните разлики помеѓу алгоритмите со носечки вектори кои се користат за решавање на проблем со класификација и на регресија се сумирани во Табела 3-3.

Табела 3-3: Основни разлики помеѓу алгоритмите со носечки вектори за класификација и за регресија.

Карактеристика	Машина со носечки вектори за класификација	Модел на регресија со носечки вектори
<i>Применливост</i>	Класификација на податоци	Предвидување на континуирани вредности
<i>Излезна вредност</i>	Дискретна класа (+1 или -1)	Континуирана вредност
<i>Хиперрамнина</i>	Граница на одлука за раздвојување на класите	Функција на предвидување која минимизира грешки
<i>Оптимизациска цел</i>	Максимизирање на маргината меѓу класите	Минимизирање на грешките во предвидувањата
<i>Ограничувања</i>	Тврда/мека маргина со казни за погрешни класификации	Толеранција ϵ за отстапување од вистинските вредности

3.3.3. Збирен модел со метод на засилување за регресија

Во Поглавјето 3.2.1. беше објаснето како се користи методот на машинско учење со метод на засилување за задачи на класификација, додека тука се обработува неговата примена за регресија. Поточно, прикажан е моделот на засилување со метод на најмали квадрати, кој претставува адаптација на алгоритмот за засилување за регресиони задачи [156], [157]. Овој алгоритам за засилување користи метод на најмали квадрати за да ги минимизира грешките при предвидувањето на континуирани вредности. Наместо да врши корекција на тежините на податоците, како кај адаптивното засилување, овој метод ги минимизира на остатоците (разликите меѓу вистинските и предвидените вредности) во секој чекор од алгоритмот. Алгоритмот креира збирен модел составен од повеќе “слаби” модели наречени уште и слаби регресори (дрва на одлучување). Во секоја нова итерација од фазата на учење, се додава нов регресор кој е трениран за да ги коригира грешките на претходните, што резултира со постепено подобрување на точноста на моделот (Слика 3.14).



Слика 3.14: Подобрување на точноста на збирниот модел со метод на засилување со додавање на нов регресор во секоја итерација

На почеток на тренирањето, моделот $F_0(x)$ се иницијализира како просек на целните вредности:

$$F_0(x) = \bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \quad (3-56)$$

каде $\bar{y}$ е средната вредност на сите y_i , а N е бројот на влезните податоци.

Потоа следува итеративен процес на тренирање на моделот. За секоја итерација $m = 1, 2, \dots, M$ првично се пресметуваат остатоците $\tilde{y}_i$ кои се разликата помеѓу вистинската вредност y_i и акумулираното предвидување од тековниот збиен модел $F_{m-1}(x)$ составен од сите претходни слаби регресори до итерацијата $(m - 1)$:

$$\tilde{y}_i = y_i - F_{m-1}(x_i), \quad i = 1, \dots, N \quad (3-57)$$

Следен чекор е тренирањето на нов слаб регресор $h(x, \alpha_m)$ преку минимизација на следната функција:

$$(\rho_m, \alpha_m) = \arg \min_{\rho, a} \sum_{i=1}^N (\tilde{y}_i - \rho \cdot h(x_i; a))^2 \quad (3-58)$$

каде што ρ_m е тежината (скалирањето) на слабите регресори, а α_m се параметрите на слабите регресори. Потоа се ажурира збирниот модел со додавање на придонесот од новиот слаб регресор:

$$F_m(x) = F_{m-1}(x) + \rho_m \cdot h(x; \alpha_m) \quad (3-59)$$

По M итерации, се добива конечниот модел кој е збир на иницијалниот модел $F_0(x)$ и сите слаби регресори:

$$F(x) = F_0(x) + \sum_{m=1}^M \rho_m \cdot h(x; a_m) \quad (3-60)$$

Кога моделот $F(x)$ е истрениран, предвидувањата за нов податок x_* се изведуваат со следниов израз:

$$\hat{y} = F(x_*) = F_0(x_*) + \sum_{m=1}^M \rho_m \cdot h(x_*; a_m) \quad (3-61)$$

при што секој слаб регресор $h(x; a_m)$ прави предвидување за x_* . Овие предвидувања се комбинираат со нивните соодветни тежини ρ_m , и збирот на сите придонеси го дава конечниот предвиден резултат $\hat{y}$.

3.3.4. Збирен модел со метод на агрегирање за регресија

Алгоритмот за збирен модел базиран на агрегирање со повеќекратно избирање примероци, покрај примената за задачи за класификација (детално објаснето во Поглавје 3.2.2.), исто така се користи и за регресиони задачи. Основната идеја е паралелно комбинирање на повеќе независно обучени модели со цел да се предвиди континуирана вредност во зависност од влезни податоци [158]. Додека кај класификацијата агрегирањето за добивање краен резултат користи „мнозинско гласање“ на истренирани слаби модели, кај регресијата предвидувањата од индивидуалните модели се агрегираат преку пресметување на нивниот просек.

Овој алгоритам работи на начин да од оригиналното множество за тренирање $D = \{(x_i, y_i)\}_{i=1}^N$, се креираат B подмножества D_b , каде $b = 1, 2, \dots, B$, со метод на повеќекратно избирање примероци. Секое подмножество D_b е од истата големина N , но може да содржи повторени податоци од влезното множество.

Потоа, за секое подмножество D_b се тренира независен модел $f_b(x)$, кој предвидува континуирана вредност y . Конечната предвидена вредност $\hat{y}$ за нов влезен податок x се пресметува како аритметичка средина од независните предвидувања на сите слаби модели во збирниот модел:

$$\hat{y} = \frac{1}{B} \sum_{b=1}^B f_b(x) \quad (3-62)$$


каде B е бројот на независно обучени модели во ансамблот, и $f_b(x)$ е предвидувањето на b -тиот модел за влезниот податок x .

3.3.5. Вештачки невронски мрежи

Вештачката невронска мрежа (ВНМ) е алгоритам со машинско учење за моделирање и предвидување на нелинеарни односи во податоците, дизајниран да функционира како вештачки човечки мозок [159]. При дизајнирање на ВНМ, се конструираат слоеви од меѓусебно поврзани јазли или „неврони“ кои обработуваат и пренесуваат информации, слично на нервните клетки во човечкиот мозок [160].

Структурата на вештачката невронска мрежа се состои од повеќе компоненти кои работат заедно за обработка на податоците и за предвидување на резултатите. Основната структура на ВНМ вклучува слоеви, неврони, врски помеѓу нив, тежини на врските, компензации, и активациони функции, со кои се трансформираат влезните податоци во излезни резултати, овозможувајќи на мрежата да моделира сложени нелинеарни односи.

ВНМ е организирана во три типови на слоеви: влезен слој, скриени слоеви и излезен слој. Структурата на една ВНМ е прикажана на Слика 3.15, каде со $x_1, \dots, x_5$ се прикажани податоците кои се влезови во мрежата, а со y податоците за излезот кој се моделира.



Слика 3.15: Структура на вештачка невронска мрежа со влезови $x_1, \dots, x_5$, излез y , и трите типови на слоеви прикажани со нивните меѓусебни поврзувања

Влезниот слој е првиот слој во мрежата, кој ги прима податоците во форма на влезни карактеристики $x = [x_1, x_2, \dots, x_n]$ каде што n е бројот на карактеристики во множеството на податоци. Влезниот слој не врши пресметка и само ги пренесува влезните податоци до следниот (скриен) слој. Во скриените слоеви се одвива обработката на податоците. Мрежата може да содржи еден или повеќе скриени слоеви, а доколку бројот на скриени слоеви е над три тогаш таа се смета за длабока невронска мрежа. Овие слоеви се состојат од неврони кои применуваат линеарни трансформации на влезовите, додадени со вредности на компензации, и потоа користат активациона функција за генерирање на излез од секој неврон. Невроните од последователни слоеви се поврзани помеѓу себе со конекции и тие го дефинираат патот на пренесувањето на информациите во мрежата. Секоја конекција има тежина w која го претставува степенот на влијание на излезот на еден неврон врз друг. Дополнително, на секој неврон во скриените слоеви и (најчесто и кај) излезниот слој се додава компензација b која е дополнителна вредност што му овозможува на моделот да ги помести границите на одлучување и да се прилагоди на различни видови на податоци. Излезот на еден неврон $z_j^{(l)}$ во слојот со реден број l е:

$$z_j^{(l)} = \sum_{i=1}^{n^{(l-1)}} w_{ji}^{(l)} a_i^{(l-1)} + b_j^{(l)} \quad (3-63)$$


каде што:

- $z_j^{(l)}$ е влезот во j -тиот неврон во слојот l ,
- $w_{ji}^{(l)}$ е тежината на врската помеѓу i -тиот неврон од претходниот слој и j -тиот неврон во тековниот слој,
- $a_i^{(l-1)}$ е излезот на i -тиот неврон од претходниот слој,
- $b_j^{(l)}$ е компензацијата за j -тиот неврон,
- $n^{(l-1)}$ е бројот на неврони во претходниот слој.

За да се воведат нелинеарност во моделот и/или да се одреди дали и колку одреден неврон ќе придонесе во процесот на предвидување на невронот се додава активациона функција. Активационата функција $\phi(z)$ се применува на пресметката $z_j^{(l)}$ за да се генерира финалниот излез на невронот кој ја добива следната форма:

$$a_j^{(l)} = \phi(z_j^{(l)}) \quad (3-64)$$





Релациите и пресметките во еден неврон со реден број j од слојот l се визуелно илустрирани на Слика 3.16.



Слика 3.16: Приказ на операциите кои се вршат во неврон со реден број j кој припаѓа во слојот со реден број l

Во зависност од примената и архитектурата на мрежата, постојат различни типови на активациони функции. Графички приказ како и равенка на најчесто применуваните се прикажани во Табела 3-4 [161].

Табела 3-4: Најчесто применувани активациони функции кај вештачките невронски мрежи [161]

Sigmoid	Tanh	ReLU	Leaky ReLU
$\phi(z) = \frac{1}{1 + e^{-z}}$	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	$\phi(z) = \max(0, z)$	$\phi(z) = \max(\epsilon \cdot z, z); \epsilon \ll 1$
			

Излезниот слој е завршниот дел од мрежата и во овој слој се генерира финалниот излез $\hat{y}$. Кај задачи за регресија, овој слој обично не користи активациона функција, што овозможува директно предвидување на континуирани вредности според следната равенка:

$$\hat{y} = \sum_{i=1}^{n^{(L-1)}} w_i^{(L)} a_i^{(L-1)} + b^{(L)} \quad (3-65)$$

каде L е бројот на слоеви во мрежата $w_i^{(L)}$ се тежините во излезниот слој, $a_i^{(L-1)}$ е излезот на i -тиот невррон од претходниот слој (последниот скриен слој), и $b^{(L)}$ е компензацијата.

Процесот на тренирање на вештачката невронска мрежа започнува со иницијализација на тежините и компензациите на секој невррон. Првично, овие вредности се поставуваат со произволна вредност. Тренирањето на невронската мрежа се состои од следните чекори: пропација напред, пресметка на грешката, обратна пропација, и ажурирање на тежините и компензациите. Овие чекори се повторуваат за повеќе итерации (епохи). Со секоја наредна итерација мрежата се стреми да ги намали грешките што ги прави и да ја зголеми точноста на предвидувањето со оптимизирање и подобрување на параметрите кои ги содржи. Подолу е дадено објаснување на секој чекор поединечно во фазата на тренирање:

- Чекор 1: Пропагација напред

Во овој чекор, влезните податоци x се проследуваат низ мрежата за да се генерира излезниот резултат $\hat{y}$. Секој невррон во скриените слоеви го пресметува збирот на своите влезови со соодветните тежини и применува активациска функција.

- Чекор 2: Пресметка на грешката

Откако ќе се добие предвидениот излез $\hat{y}$, истиот се споредува со вистинската вредност на излезот y од множеството на податоци за тренирање. Разликата помеѓу очекуваната y и предвидената вредност $\hat{y}$ ја претставува грешката во предвидувањето на мрежата со така дефинирани тежини и компензации. Функцијата за загуба $\mathcal{L}(y, \hat{y})$ ја мери оваа грешка. Најчесто користена функција за загуба при тренирање на ВМ за регресија е мерката средна квадратна грешка која се пресметува на следниот начин:

$$\mathcal{L}(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3-66)$$

каде што N е бројот на примероци.

- Чекор 3: Обратна пропација

Со цел мрежата да научи од грешката, таа се проследува наназад низ мрежата почнувајќи од излезниот слој кон почетниот слој. Обратната пропација е метод преку кој невронската мрежа ја користи грешката добиена на излезот за да ги ажурира претходните тежини и компензации [162]. При овој процес се пресметуваат градиентите на загубата во однос на избраните тежини и компензации, односно се следи како и колку промената на тежините и компензациите влијае врз промената на вкупната грешка.

- Чекор 4: Ажурирање на тежините и компензациите со метод на намалување на градиентот

Методот на намалување на градиентот е алгоритам за оптимизација кој ги користи пресметаните градиенти од чекор 3 за да ги ажурира тежините w и компензациите b на мрежата, со цел минимизирање на функцијата на загуба $\mathcal{L}$. Овој метод итеративно ги прилагодува параметрите на моделот, постепено менувајќи им ги вредностите за да ја намали вредноста на функцијата за загуба, сè додека не се постигнат параметрите што овозможуваат најмала можна загуба. Овој алгоритам ги ажурира параметрите на следниот начин:

$$w^{(l)} \leftarrow w^{(l)} - \eta \frac{\partial \mathcal{L}}{\partial w^{(l)}} \quad (3-67)$$

$$b^{(l)} \leftarrow b^{(l)} - \eta \frac{\partial \mathcal{L}}{\partial b^{(l)}} \quad (3-68)$$

Новите тежини и компензации се добиваат со одземање на производот на стапката на учење η и соодветниот градиент. Стапката на учење η ја одредува вредноста на промената на параметрите кога алгоритмот прави нивно ажурирање.

Овие ажурирања се повторуваат за сите слоеви во мрежата и се извршуваат за секоја итерација додека функцијата на загуба $\mathcal{L}$ не се минимизира. Со секоја наредна итерација, мрежата “учи” за зависностите во податоците во множеството за тренирање и ги подобрува параметрите, со што ја минимизира грешката и ја зголемува точноста на своите предвидувања.

3.4. Анализа на главни компоненти

Анализата на главни компоненти (Principle Component Analysis – PCA), воведена од Карл Пирсон во 1901 година [163], претставува метод за намалување на димензионалноста на множество на податоци, притоа зачувувајќи што е можно повеќе од нивната варијанса. Овој метод ја трансформира оригиналната група на променливи во нова група на некорелирани променливи, наречени главни компоненти, кои се помалку на број од оригиналните променливи и се комбинација од оригиналната група на променливи со соодветен тежински фактор. Главните компоненти се подредени така што првите неколку содржат најголем дел од варијацијата присутна во оригиналното множество на податоци. Шематски приказ на алгоритмот е даден на Слика 3.17.



Слика 3.17: Шематски приказ на принципот на работа на алгоритмот анализа на главни компоненти

Пред да се примени PCA потребно е да се стандардизираат податоците, особено кога променливите имаат различни мерни единици или варијанси. Стандардизацијата ги прилагодува податоците така што тие имаат средна вредност еднаква на нула и стандардна девијација еднаква на еден.

За математички да се дефинира алгоритмот, нека X е стандардизираното множество на податоци со вкупно n податочни точки. PCA започнува со пресметување на матрицата на коваријанса C :

$$C = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \quad (3-69)$$

Следниот чекор во алгоритмот е разложување (декомпозиција) на коваријантната матрица C на нејзините сопствени вредности (λ) и сопствени вектори (v). Сопствените вредности на C ги мерат количините на варијанса што ги претставуваат соодветните сопствени вектори, и се добиваат со решавање на карактеристичната равенка:

$$Cv = \lambda v \quad (3-70)$$

каде што C е матрица на коваријанса, λ е сопствената вредност на C , а v е сопствениот вектор на C , кој одговара на дадената сопствена вредност. Секој сопствен вектор v претставува насока во просторот на податоците, додека соодветната сопствена вредност λ ја одредува количината на варијанса во таа насока.

Главните компоненти се добиваат со подредување на сопствените вредности по нивната големина, при што првата главна компонента има најголема сопствена вредност и, со тоа, објаснува најголем дел од вкупната варијанса во множеството на

податоци. Втората главна компонента содржи најголем можеен дел од преостанатата варијанса, но е ортогонална (некорелирана) со првата, и така натаму.

Процентот на вкупната варијанса E што ја објаснува k -тата главна компонента се пресметува како:

$$E = \frac{\lambda_k}{\sum_{i=1}^d \lambda_i} \quad (3-71)$$

каде што: λ_k е сопствената вредност на k -тата компонента, а d е вкупниот број на димензии во оригиналните податоци. Според оваа метрика се врши изборот на број на главни компоненти што треба да се задржат, најчесто така што се задржуваат само оние компоненти што објаснуваат најголем процент од вкупната варијанса (најчесто над 95%).

РСА користи линеарна трансформација за да ја зачува максималната варијанса во податоците додека го намалува бројот на димензии. Оригиналните податоци се проектираат врз главните компоненти за да се добијат поените на главните компоненти, кои ја претставуваат вредноста на секој податок во новиот координатен систем дефиниран од главните компоненти. Трансформацијата на оригиналните податоци X во нови координати Y се постигнува преку скаларен производ помеѓу матрицата на податоци X и матрицата на сопствени вектори W :

$$Y = X \cdot W \quad (3-72)$$

каде што:

- Y е матрицата на поените на главните компоненти,
- X е стандардизираната матрица на податоци,
- W е матрицата составена од сопствените вектори (v).

Преку оваа трансформација, податоците се претставуваат во нов координатен систем дефиниран од главните компоненти кој овозможува ефикасно намалување на димензионалноста со задржување на најголем дел од варијансата во влезните податоци, што овозможува нивна поефикасна анализа и интерпретација.

3.5. Метрики за евалуација на точноста на моделите со машинско учење

За да се оцени способноста на предвидување на моделите за класификација со машинско учење во примената на ова истражување, точноста на моделот е

пресметана како однос на бројот на точни предвидувања и вкупниот број на влезни податоци:

$$\text{Точност} = \frac{\text{Број}_{\text{точни предвидувања}}}{\text{Број}_{\text{влезни податоци}}} \quad (3-73)$$

Дополнително, користени се стандардни метрики за евалуација на способноста за класификација на алгоритмот, вклучувајќи ја стапката на вистински позитиви (True Positive Rate - TPR), вредностите на позитивни предвидувања (Positive Predictive Value - PPV), стапката на лажно негативни (False Negative Rate - FNR) и стапката на лажни откритија (False Discovery Rate - FDR), каде што:

- FNR претставува пропорција на погрешно класифицирани податоци во однос на вистинската класа.
- FDR претставува пропорција на погрешно класифицирани податоци во однос на предвидената класа.
- TPR претставува пропорција на точно класифицирани податоци во однос на вистинската класа.
- PPV претставува пропорција на точно класифицирани податоци во однос на предвидената класа.

Вредностите на овие метрики за референтна класа се пресметуваат на следниот начин:

$$TPR = \frac{TP}{TP + FN} \quad (3-74)$$

$$PPV = \frac{TP}{TP + FP} \quad (3-75)$$

$$FNR = \frac{FN}{FN + TP} \quad (3-76)$$

$$FDR = \frac{FP}{FP + TP} \quad (3-77)$$

каде што:

- вистински позитиви (True Positives - TP) се бројот на резултати што точно го предвидуваат присуството на референтната класа;
- вистински негативи (True Negatives - TN) се бројот на резултати што точно го предвидуваат отсуството на референтната класа;
- лажни позитиви (False Positives - FP) се бројот на резултати што погрешно го предвидуваат присуството на референтната класа;

- лажни негативи (False Negatives - FN) се бројот на резултати што погрешно го предвидуваат отсуството на референтната класа.

За да се оцени точноста на предвидувањето на обучените регресиони модели, користен е коефициентот на решителност (R^2) кој претставува мерка за тоа колку добро предвидените вредности се совпаѓаат со вистинските вредности. Овој коефициент се дефинира како:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3-78)$$

каде што:

- y_i се вредностите на влезните податоци,
- $\hat{y}_i$ се предвидените вредности од моделот,
- $\bar{y}$ е средната вредност на вредностите од влезните податоци,
- n е бројот на податоци.

Коефициентот R^2 ја мери пропорцијата на варијансата во зависната променлива што може да се објасни со независните променливи. Неговата вредност се движи помеѓу 0 и 1, при што:

- $R^2 = 1$ означува дека моделот совршено ги објаснува податоците,
- $R^2 = 0$ означува дека моделот не објаснува никаква варијанса во зависната променлива,
- R^2 блиску до 1 укажува на висока точност на предвидување, додека ниска вредност означува модел со ниска точност на предвидување.

Дополнително, за подлабока анализа на точноста на моделот, разгледана е и метриката на корен од средната квадратна грешка (RMSE), кој се дефинира како:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3-79)$$

$$RMSE = \sqrt{MSE} \quad (3-80)$$

За да се анализираат резултатите од анализата со главни компоненти (PCA), се користи график на проектираните координати, или „поените“, на значајните главни компоненти, кој овозможува визуелна проценка на одделувањето на различните кластери според нивните карактеристики. Овој график прикажува како податоците се распоредени во просторот на првите неколку главни компоненти, овозможувајќи идентификација на групирања и потенцијални сличности или разлики меѓу податоците.

3.6. Физички закони применети во спектроскопијата

Спектроскопијата претставува гранка на физиката која ги проучува интеракциите помеѓу електромагнетното зрачење и материјата, како функција од бранова должина, фреквенција или енергија. Основниот принцип на спектроскопијата е дека секој атом, молекула или јонизирана честичка има уникатен спектар на зрачење, што овозможува анализа на хемискиот состав и физичките својства на материјалот.

3.6.1. Атомски енергетски нивоа и електронски транзиции

Енергетските нивоа на електроните во атомот и неговата структура можат да се опишат со Боровиот модел [164]. Според овој модел, електронот што орбитира околу атомското јадро со атомски број Z има енергија дадена со:

$$E_n = -R_\infty \frac{Z^2}{n^2} \quad (3-81)$$

каде што:

- $R_\infty \approx 13.6 \text{ eV}$ е Ридберговата константа,
- n е главен квантен број ($n = 1, 2, 3, \dots$) каде што $n = 1$ ја претставува основната (најниска) енергетска состојба.

Овие енергетски состојби се дискретни, што значи дека електронот не може да има енергија помеѓу две нивоа. Но доколку се доведе енергија тогаш може да транзитира од ниско кон повисоко ниво [165]. Бидејќи вака состојбата е нестабилна, при враќањето на електронот во првобитно енергентско ниво се емитира фотон со енергија [166]:

$$E_{ph} = E_i - E_f = R_y \left(\frac{1}{n_f^2} - \frac{1}{n_i^2} \right) \quad (3-82)$$

каде што $R_y = hcR_\infty$ е Ридберговата енергија, E_i и E_f се енергиите на почетната и крајната состојба, n_i и n_f се квантните броеви на овие состојби.

Енергијата на фотонот $E_{ph} [J]$ која е директно зависна од разликата помеѓу двете енергетски нивоа на транзиција на електронот ја дефинира брановата должина на фотонот кој е емитиран:

$$E_{ph} = \frac{hc}{\lambda} \quad (3-83)$$

каде што:

- h е Планковата константа, $h = 6.626 \times 10^{-34} [J \cdot s]$
- c е брзината на светлината во вакуум, $c = 3 \times 10^8 [m/s]$
- λ е бранова должина на фотонот $[m]$


Бидејќи:

$$\frac{c}{\lambda} = \nu \quad (3-84)$$

каде што ν е фреквенцијата на емитираниот фотон, равенката (3-84) може да се напише во следниот облик:

$$E_{ph} = h\nu \quad (3-85)$$

Шематски приказ на процесот на апсорпција и емисија на фотон е даден на Слика 3.18.



Слика 3.18: Шематски приказ на апсорпција и емисија на фотон при енергетски транзиции на електронот во атомот

Енергетските транзиции се основа за формирање на спектралните линии [167]. Следствено, енергетската разлика може да се претстави преку брановата должина:

$$\frac{1}{\lambda} = R_{\infty} Z^2 \left(\frac{1}{n_f^2} - \frac{1}{n_i^2} \right) \quad (3-86)$$

Оваа формула покажува дека секој електронски преод во атомот генерира емитираното зрачење со специфична бранова должина, што овозможува идентификација на елементите преку спектроскопија.

Како што беше спомнато, за да се случи транзиција на електрони, атомите мора да апсорбираат енергија. Во процесот на LPBF, оваа енергија ја донесува снопот на ласерски зрак. Фотоните од ласерот, со одредена енергија, се апсорбираат од електроните во металниот прав, што доведува до нивна возбуда во повисоки енергетски нивоа. При враќање во пониски нивоа, електроните емитираат фотони со фреквенција пропорционалната на разликата во енергетските нивоа.

Соодветно на тоа, за атоми од истиот елемент, при транзиции на електроните низ различни енергетски нивоа, се воочуваат различни емисиони линии на различна бранова должина со различен интензитет.

Дополнително, во услови на високи енергии, како кај LPBF процесите, електронот може да ја надмине енергијата на врзување во атомот и целосно да се оддели од него. Ова се нарекува процес на јонизација, а атомот станува позитивно наелектризиран јон. Слободните електрони се судираат со други атоми, предизвикувајќи дополнителна јонизација, при што се формира плазмен облак над стопената зона. Овој облак се состои од слободни електрони, јони и неутрални атоми. Доколку внесената енергија е екстремно висока, може да се случи целосна јонизација, при што сите атоми во системот стануваат јони и електрони. Во случаи со пониска енергија, се јавува парцијална јонизација, каде што во плазмата истовремено се присутни и неутрални атоми и јони. Како пример, кај железото (Fe), Fe I се однесува на нејонизирана состојба на железото, што значи дека електроните остануваат во нивните оригинални орбити во атомот. Од друга страна, Fe II претставува првата јонизирана состојба, што значи дека железото изгубило еден електрон и станало позитивно наелектризирано (Fe^+). Со понатамошно зголемување на енергијата, железото може да премине во Fe III, што означува втор степен на јонизација (Fe^{2+}), и така натаму.

Важно е да се напомене дека создавањето плазмата која е индуцирана од ласер зависи од експерименталните услови, вклучувајќи ги параметрите на ласерот, брановата должина на ласерското зрачење, интензитетот на ласерското зрачење, големината на фокусираната точка на ласерскиот сноп, морфологијата на парчето и околината [168].

3.6.2. Линиски и континуиран емисионен спектар

Емитираните фотони создаваат спектрални линии со специфична бранова должина и интензитет, зависно од енергетските нивоа меѓу кои се случува електронската транзиција, типот на атомот или јонот, како и од условите во плазмата, како што се температурата и густината на честичките. Наједноставниот спектар е линискиот спектар, кој се состои од една или повеќе спектрални линии [169]. Овие линии можат да бидат емисиони линии или апсорпциони линии.

Принципот на неизвесност на Хајзенберг ја претставува неизвесноста меѓу енергијата на фотонот и времетраењето на возбуда [170], според следната релација:

$$E_{ph} \cdot \tau \geq \frac{h}{2\pi} \quad (3-87)$$

каде што E_{ph} е енергијата на фотонот, τ претставува времето во кое електронот останува во возбуда пред да се врати во основната состојба, а h е Планковата константа. Оваа релација објаснува дека не може истовремено точно да се дефинира енергијата на фотонот и времето во кое атомот останува во возбудена состојба.

Согласно равенка (3-84), равенката (3-87) може да се напише во облик:

$$\Delta\nu \geq \frac{1}{2\pi \cdot \tau} \quad (3-88)$$

со која се опишува природната ширина на спектралната линија во фрекфентен домен, и покажува дека ширината на спектралната линија ($\Delta\nu$) е инверзно пропорционална на времетраењето на возбуда (τ).

Природната ширина е минималната ширина што спектралната линија може да ја има. Дополнително, може да дојде до проширување на спектралните линии поради [171]:

- термички осцилации на атомите при повисоки температури, што доведува до проширување на линиите заради поместување на фреквенцијата на емитираниот фотон заради Доплеров ефект,
- притисокот и густината на плазмата доведуваат до судири меѓу честичките, што ги менува енергетските нивоа и ја проширува линијата.

Во плазмата може да се случи спектралните линии да се намалени или сосема да исчезнат поради самоапсорпција, која е појава кога емитираното зрачење од еден атом веднаш се апсорбира од друг, намалувајќи го детектираниот интензитет.

Линискиот спектар се формира од транзиции на електроните меѓу дискретни енергетски нивоа, при што секоја транзиција создава спектрална линија со

специфична бранова должина. Сепак, во услови на висока температура и густина, како што е случај во плазмата, индивидуалните спектрални линии се прошируваат и преклопуваат. Како што бројот на преклопувањата расте, границите меѓу дискретните линии стануваат сè понејасни, што доведува до формирање на континуиран спектар [172]. Скоро сите мерени спектри имаат континуирана компонента, која може да варира по интензитет. Дури и со многу тесни линиски спектри, постои континуирана позадина како резултат на шумови.

Дополнително, кога материјалот е загреан, тој емитира електромагнетно зрачење како резултат на термичкото движење на честичките, наречено термичка радијација. Ова зрачење во континуираниот спектар се гледа како базна линија над која се издигнуваат спектралните линии. Сите објекти со температура над апсолутната нула (0 K, -273.15 °C) емитираат енергија во форма на електромагнетно зрачење. Црното тело е теоретски модел кој апсорбира целосно сè што паѓа врз него без да рефлектира или пренесува зрачење [173]. Тоа претставува „совршен” апсорбер и „совршен” емитер на зрачење на сите бранови должини.

Планковиот закон за термичка радијација го опишува спектралното распределување низ брановите должини на термичката енергија што ја емитира црното тело, зависно од температурата [174]. Колку е повисока температурата, толку повеќе зрачење се емитира на секоја бранова должина, со максимум на интензитет на специфична бранова должина која зависи од температурата. На пример, на собна температура едно тело емитира термичка радијација која претежно е во инфрацрвениот опсег и е невидлива за човечкото око. При повисоки температури, интензитетот на инфрацрвена радијација се зголемува и може да се почувствува како топлина, а телото почнува видливо да свети со црвена боја. При уште повисоки температури, телото свети со жолта или сино-бела боја и емитира зрачење со кратки бранови должини, вклучувајќи ултравиолетово и X-зрачење. Површината на Сонцето (~5500 °C) емитира инфрацрвена и ултравиолетова радијација со голем интензитет, со максимум на емисијата во видливиот спектар.

Планковата равенка дефинира како интензитетот на зрачењето зависи од брановата должина λ и температурата T со што се опишува зрачењето на црното тело:

$$E(\lambda, T) = \frac{2hc^2}{\lambda^5} * \frac{1}{e^{\left(\frac{hc}{\lambda kT}\right)} - 1} \quad (3-89)$$

и ги вклучува константите $h = 6.626 \times 10^{-34} \text{ [J} \cdot \text{s]}$ која е Планкова константа, $c = 3 \times 10^8 \text{ [m/s]}$ е брзината на светлината во вакуум, $k = 1.381 \times 10^{-23} \text{ [J/K]}$ е Болцмановата константна.

Планковата равенка важи за емитери кои се однесуваат како црно тело (со емисионен коефициент еднаков на 1). Реалните тела имаат емисионен коефициент

кој може да биде значително помал и зависи од различни фактори како што се аголот на пад на зрачењето, аголот на емисија, брановата должина на емитираното зрачење и состојбата на површината на материјалот [175]. Ова значи дека за повеќето материјали во реални услови, емисијата на термичка радијација варира во зависност од геометријата, структурата и физичките својства на површината [175]. И покрај тоа што реалните материјали не се совршени црни тела, во анализата на термичката радијација при LPBF процесите, зоната на топење може да се апроксимира како црно тело бидејќи растопениот метал има зголемена апсорптивност и емисија во инфрацрвениот опсег, а високата температура придонесува кон приближување до идеалните услови за зрачење.


Како заклучок, континуираниот спектар во спектроскопската анализа на LPBF процесите се состои од термичка радијација, која може да се апроксимира со Планковиот закон, и спектрални екстреми, кои потекнуваат од емисијата на поединечни атоми или јони. Со раздвојување на овие две компоненти, во ова истражување се спроведени две независни анализи:

1. Анализа на термичката радијација: користејќи го Виеновиот закон за поместување на зрачењето, може да се процени температурата на црното тело, односно температурата на зоната на топење во LPBF.

2. Анализа на спектралните екстреми: користејќи го Болцмановиот график, може да се анализираат релативните интензитети на емисионите линии за да се одреди температурата на електроните во плазмата во процесот.

3.6.3. Виенов закон за поместување на зрачењето за проценка на температурата на црното тело

Кога температурата на црното тело се зголемува, вкупната емитирана енергија се зголемува, а максимумот на емисионата крива се поместува кон пократки бранови должини. Виеновиот закон за поместување на зрачењето вели дека кривата на зрачење на црно тело за различни температури ќе достигне максимум на различни бранови должини кои се инверзно пропорционални на температурата [176], како што е илустрирано на Слика 3.19.



Слика 3.19: Спектрална распределба и максимум на кривата на зрачење за различни температури на црното тело според Виеновиот закон за поместување на зрачењето [177]

Ова поместување е директна последица на Планковиот закон за зрачење, кој го опишува спектралниот интензитет на зрачење како функција на брановата должина за одредена температура [178]. Тоа значи дека производот на брановата должина на максимумот на кривата на термичка радијација λ_{max} и температурата на црното тело е константа. Ова се опишува од равенката на Виеновиот закон:

$$\lambda_{max} \cdot T = b \quad (3-90)$$

каде што T е апсолутната температура, а $b = 2.8978 \times 10^{-3} [m \cdot K]$ е константа на пропорционалност наречена Виенова константа за поместување. Виеновиот закон го опишува инверзниот однос меѓу температурата и брановата должина: повисока температура значи пократка бранова должина на емитираното зрачење, додека пониска температура значи подолга бранова должина. Доколку се разгледува максимумот по фреквенција, потребно е да се користи друга константа на пропорционалност, но законот останува ист: брановата должина на максимумот е инверзно пропорционална на температурата, додека фреквенцијата на максимумот е директно пропорционална на температурата.

Виеновиот закон овозможува пресметување на температурата на тела со високи температури, како што се ѕвездите, но и на температурата на зоната на топење во

LPBF процесот, кога е позната брановата должина на максимумот на кривата на термичка радијација.

3.6.4. Метод на Болцманов график за проценка на температурата на електроните во плазмата

Температурата на електроните во плазмата може да се одреди со анализа на спектралните линии од енергетските транзиции на одреден елемент, користејќи ја Болцмановата равенка за интегрирана емисија по бранова должина [179], [180]. Според оваа равенка, интензитетот на емитираното зрачење при преодот од повисоко (k) кон пониско (i) енергетско ниво I_{ki} е даден со изразот:

$$I_{ki} = \frac{1}{4\pi} \cdot \frac{h \cdot c}{\lambda} \cdot \frac{N^Z}{U(T)} \cdot g_k \cdot A_{ki} \cdot e^{-E_k/kT} \quad (3-91)$$

каде што:

- I_{ki} – интензитетот на емитираното зрачење при преодот меѓу енергетски нивоа од k кон i ,
- h – Планкова константа,
- c – брзина на светлината во вакуум,
- λ – бранова должина на емисионата линија,
- N^Z – вкупната густина на честички во јонската состојба z ,
- $U(T)$ – партициска функција на температурата T ,
- g_k – дегенерација на повисокото енергетско ниво,
- A_{ki} – веројатност за преод (коефициент на спонтано емитирање),
- E_k – енергија на повисокото ниво k ,
- $k = 1.380649 \times 10^{-23} \text{ [J/K]}$ – Болцманова константа,
- T – температура на електроните во плазмата.

Со логаритмирање на двете страни на равенката (3-91) и прераспределба на членовите, се добива:

$$\ln\left(\frac{I_{ki} \cdot \lambda}{g_k \cdot A_{ki}}\right) = \ln\left(\frac{h \cdot c \cdot N^Z}{4\pi \cdot U(T)}\right) - \frac{E_k}{kT} \quad (3-92)$$

Равенката (3-92) има линеарна форма $y = mx + c$ каде што изразот на левата страна $\ln\left(\frac{I_{ki} \cdot \lambda}{g_k \cdot A_{ki}}\right)$ е ординатата, E_k е апсцисата, а T е непознатата x . Бидејќи за одредување на ординатата и апсцисата се користи збир од повеќе спектрални линии, средниот

член $\ln\left(\frac{h \cdot c \cdot N^Z}{4\pi \cdot U(T)}\right)$ (константниот член) не е неопходно да се пресмета за целта на ова истражување.

Откако податоците се поставени на x и y оска и се моделирани со линеарна регресија, од равенката на линеарниот модел може да се добие вредноста на наклонот. Штом оваа вредност е позната, може да се пресмета температурата на електроните во плазмата, бидејќи наклонот на линеарната релација е негативен обратен однос на производот на Болцмановата константа и температурата на електроните, односно е еднаков на:

$$m = -\frac{1}{kT} \quad (3-93)$$

За да се зголеми прецизноста на линеарното моделирање, опсегот на горните енергетски нивоа треба да биде што е можно поголем. Важно е дека при користење на методот на Болцманов график мора да се користат емисионите линии од истиот елемент и истата јонизациска состојба.

За овој метод да биде валиден, мора да бидат исполнети претпоставките дека плазмата се наоѓа во локална термодинамичка рамнотежа и дека спектралните линии се оптички тенки, односно нема значителна самоапсорпција [181].

Со користење на овој метод за анализа на спектралните емисии добиени од LPBF процесот, внесот на енергија во материјалот може да се определи како резултат на формирање на плазма [182]. Варијациите во температурата на електроните можат да укажат на дефекти во процесот, предизвикани од прекумерен или недоволен внес на енергија, што резултира со различни дефекти во финалното парче [183].

3.7. Заклучоци за поглавјето

Во ова поглавје се поставени теоретските основи за двата применети методи неопходни за спроведување на истражувањето: со машинско учење и со физички закони. Од него произлегуваат следните заклучоци:

- Разработени се основните концепти, категории и математички принципи на алгоритмите за машинско учење кои се применети во истражувањето, со фокус на надгледувано учење (класификација и регресија) и ненадгледувано учење (анализа на главни компоненти).
- Метриците за евалуација кои се објаснети и понатаму се користени за споредба на моделите со машинско учење се: точност, стапка на вистински позитиви (TPR), вредност на позитивни предвидувања (PPV), стапка на

лажно негативни (FNR), стапка на лажни откритија (FDR) за класификационите модели, како и коефициентот на решителност (R^2) и корен од средна квадратна грешка (RMSE) за регресионите модели. Дополнително, за ненадгледуваниот модел, односно за анализата на главни компоненти се користи график на проектираните координати, или „поените“, на значајните главни компоненти.

- Презентирани се физичките основи на спектроскопијата и законите поврзани со анализа на емисиони спектри, вклучувајќи закони за електронски транзиции, температура на „црно тело“ и температура на електрони во плазма, кои се применувани во истражувањето.
- Поглавјето воспоставува основа за интердисциплинарен пристап, интегрирајќи методи од вештачката интелигенција и физиката, како подготовка за развој и примена на интелигентен мониторинг систем во LPBF процесот.

4. ЕКСПЕРИМЕНТАЛНА ОПРЕМА

Во ова поглавје се опишуваат карактеристиките на експерименталната опрема која се користи во рамките на ова истражување, како и имплементацијата на мониторинг системот за следење на процесот во реално време со цел постигнување на истражувачките цели.

Прво, детално се опишува LPBF платформата, вклучувајќи ги нејзините технички карактеристики и конфигурацијата на оптичкиот ланец со вградените оптички елементи. Потоа се претставуваат техничките карактеристики на спектрометарот кој служи како сензор за мониторинг на процесот.

Понатаму е објаснет процесот на интеграција на спектрометарот во LPBF машината, при што за потребите на истражувањето се развиени и имплементирани мониторинг системи во две различни конфигурации: коаксијално и надвор од главата на скенирање на ласерот.

На крај, се презентира метод за пресметка на кривата на преносливост на оптичкиот пат, што е од суштинско значење за калибрација и корекција на спектралните мерења. Оваа крива се применува во сите понатамошни експерименти за обезбедување точност и кохерентност на спектралните информации со обработениот материјал.

Целата експериментална работа беше реализирана во лабораторијата SITEC - Laboratory for Laser Applications која функционира во рамки на Одделот за машинско инженерство, сектор за производство и производни системи при Политехничкиот универзитет во Милано, Италија (Department of mechanical engineering - Manufacturing and production systems, University Politecnico di Milano,

Italy). Лабораторијата и вработениот кадар ја обезбедија целокупната експериментална опрема, материјали, мерна опрема, финансиски средства, како и стручна експертиза и поддршка неопходни за спроведување на истражувањето. Експерименталниот дел од истражувањата е направен во текот на пет студентски престои во следните периоди:

(1) 09.04.2022 – 16.04.2022

(2) 20.06.2022 – 30.07.2022

(3) 07.09.2022 – 16.09.2022

(4) 03.07.2023 – 31.07.2023

(5) 04.09.2023 – 29.09.2023


4.1. Конфигурација и оптички компоненти на експерименталната LPBF машина

Експерименталната работа беше спроведена на LPBF платформа за адитивно производство на метални делови. Машината е опремена со ласер со единечен модул (IPG Photonics YLR-300-AC-Y11, Кембриџ, Масачусетс, Соединети Американски Држави). Ласерот има максимална излезна моќност од 300 W и е способен да работи во два режими – континуиран бранов режим (Continuous Wave - CW) и пулсен бранов режим (Pulsed Wave - PW), овозможувајќи флексибилност при обработката на материјалите во зависност од специфичните барања на процесот.

Ласерот е поврзан со глава за скенирање (AM Module v1.1) произведена од Raylase (Веслинг, Германија) и прикажана шематски на Слика 4.1. Главата е дизајнирана и затворена за да обезбеди прецизно насочување на зракот кон платформата за печатење, истовремено минимизирајќи ги оптичките загуби. Дополнително, главата е опремена со коаксијална мониторинг линија во која може да се имплементира сензор и со тоа да се овозможи следење на процесниот зрак во реално време. Оваа функционалност на главата за скенирање е од особена важност за спроведување на истражувања за разбирање и оптимизација на интеракцијата помеѓу ласерот и материјалот.

За управување со стратегиите за скенирање, платформата користи приспособен софтвер за компјутерско-потпомогнато производство (Direct Machining Control, Вилниус, Литванија), кој е специјално адаптиран за LPBF машината. Софтверот е дизајниран да поддржува флексибилни стратегии за скенирање, овозможувајќи лесно приспособување на параметрите за различни геометрии и барања на производите.

За да се обезбеди синхронизација помеѓу движењето на механичкиот систем и ласерскиот процес, во системот е имплементирана контролна картичка (SP-ICE III, Raylase, Веслинг, Германија). Оваа картичка служи како интерфејс за комуникација помеѓу ласерскиот извор и главата за скенирање, овозможувајќи прецизна контрола врз секој чекор на обработката. Имплементацијата на контролата овозможува непречено функционирање на сите компоненти на системот, што е од суштинско значење за постигнување конзистентни и висококвалитетни резултати во експерименталниот процес.



Слика 4.1: Шема на главата за ласерско скенирање од Raylase (Веслинг, Германија) со интегриран модул за коаксијален мониторинг и составните оптички елементи [123]

Оптичкиот ланец на ласерот овозможува прецизно насочување и обработка на ласерскиот зрак. Ланецот започнува со колимирачка единица, поставена на крајот од оптичкото влакно преку кое се пренесува ласерскиот зрак од изворот. Оваа колимирачка единица обезбедува конзистентен и паралелен зрак, кој потоа поминува низ оптички проширувач.

По проширувачот, зракот се насочува кон систем за поместување на фокусот, кој е составен од подвижна леќа за динамичко прилагодување и фиксна фокусирачка леќа. Овој систем овозможува флексибилно прилагодување на фокусната точка во зависност од барањата на процесот.

Дихроичното огледало, поставено после системот за фокусирање, има двојна улога во ласерскиот процес. За време на обработката, го насочува ласерскиот зрак кон целната точка на платформата за градење, додека при мониторингот заради своите оптички својства го раздвојува ласерскиот зрак од емитуваната светлина. Ова овозможува емитуваната светлина од процесот да биде насочена кон мониторинг сензорот, при што се избегнува појава на презаситеност во сигналот која би можела да биде предизвикана од ласерската светлина.

Движењето на ласерскиот зрак кон платформата за печатење се постигнува со помош на две галванометриски огледала кои овозможуваат точно насочување и дефлексија на зракот низ целата работна површина.

Мониторинг линијата интегрирана во главата за скенирање овозможува коаксијално следење на процесот преку снимање на светлината што ја емитира материјалот за време на обработката. Емитираната светлина се враќа назад кон галванометриските огледала, потоа поминува низ дихроичното огледало и влегува во мониторинг оптичкиот ланец. На крајот на линијата може да се постават сензори кои ќе овозможат собирање на податоци за процесот, овозможувајќи детално анализирање и оптимизација на процесот.

Мониторинг оптичкиот ланец вклучува дихроично огледало, фокусирачка единица која се состои од подвижна леќа за прецизно позиционирање и фиксна фокусирачка леќа, како и две огледала и уште една фокусирачка леќа кои дополнително го насочуваат зракот. Оваа оптичка структура на ласерскиот оптички пат обезбедува непречено функционирање на ласерската обработка и овозможува напредно следење и анализа на процесот во реално време.

Главните технички карактеристики на отворената LPBF платформа и нејзиниот оптички ланец се сумирани во Табела 4-1. Дијаметарот на ласерската точка е определен преку теоретски пресметки засновани на карактеристиките на леќата, соодветствувајќи на теоретската $1/e^2$ вредност, објавено во публикацијата [184].

Табела 4-1: Технички карактеристики на ласерот користен на LPBF машината


Параметар	Вредност
Оперативен режим	Континуиран режим, Пулсен режим
Бранова должина на ласерска емисија	1070 nm
Максимална моќност на ласерска емисија	300 W
Фактор на квалитет на зракот (M^2)	1.05
Дијаметар на ласерска точка (d_0)	43 μm
Распределба на густина на моќност	Гаусова

Кога рефлектираната светлина од зоната на топење се враќа назад кон главата за скенирање, таа првично го дели својот пат со ласерскиот зрак со галванометриските огледала. Галванометриските огледала, како што е прикажано на кривата на нивната рефлективност на Слика 4.2, се одликуваат со висока рефлективност од околу 99.5% во опсегот на бранови должини од 900-1100 nm со што се овозможува ефикасно рефлектирање на ласерската бранова должина од 1070 nm, додека имаат


рефлективност поголема од 80% во спектралниот опсег од 200-2000 nm. Оваа спектрална изведба се усогласува со основната функција на галванометриските огледала, управувајќи со ефикасноста на ласерскиот зрак додека го минимизираат губитокот на енергија, и овозможува вклучување на дополнителни оптички компоненти за мониторинг во оптичкиот систем.

Дихроичното огледало означено со број 1 на Слика 4.1 служи за раздвојување на патот на процесната светлина од патот на мониторинг светлината. Ова огледало има специфичен површински слој, дизајниран да биде транспарентен за одредени бранови должини и непропустлив за други, со цел разликување помеѓу ласерскиот зрак и емитираната процесна светлина, што е неопходно за прецизен мониторинг на процесот. Дихроичното огледало инсталирано во главата за скенирање е високо рефлективно за бранови должини во опсегот од 900-1100 nm, што му овозможува ефективно да го насочи ласерскиот зрак кон платформата за обработка. Истовремено, огледалото е високо пропустливо за бранови должини од 400-900 nm и 1300-2100 nm (Слика 4.3), што овозможува емитираната светлина од процесот да биде насочена кон мониторинг сензорот.

Како резултат на овие својства, емисионите бранови должини во опсегот од 400-900 nm се ефективно насочени кон патот за мониторинг, иако со одредено намалување на интензитетот на сигналот. Ова е потврдено и преку експериментални мерења.



Слика 4.2: Коефициент на рефлективност на галванометриските огледала



Слика 4.3: Коефициент на а) преносливост и б) рефлективност на дихроичното огледало инсталирано во главата за скенирање

4.2. Применет спектрометар и негови карактеристики

Спектрометар Avantes 2048 USB2 (Avantes B.V., Апелдорн, Холандија), прикажан на Слика 4.4, е користен за прибирање на спектралните податоци од зоната на топење за време на експериментите, овозможувајќи мониторинг на интеракцијата помеѓу ласерот и материјалот во реално време. Клучната предност на овој спектрометар, која го оправдува неговиот избор, е неговата способност за брзо прибирање на спектрални информации во широк опсег од 200 nm до 1100 nm, покривајќи ги ултравиолетовиот (UV), видливиот (VIS) и блискиот инфрацрвен (NIR) регион на електромагнетниот спектар. Оваа покриеност овозможува детекција на различни емисиони линии кои се карактеристични за елементите присутни во материјалот што се обработува. Спектрометарот има Czerny-Turner дизајн и CCD (Charge Coupled Device) детектор со 2048 пиксели.



Слика 4.4: Спектрометар Avantes 2048 USB2 (Avantes B.V., Апелдорн, Холандија)

Сепак, при интеграција на спектрометарот во експерименталниот систем, мора да се земе предвид дека интензитетот на добиените спектри на различни бранови должини зависат од карактеристиките на преносливост на оптичкиот пат на ласерот. Оваа зависност произлегува од особините на оптичките компоненти кои може да предизвикаат загуби или преносливост само за одредени бранови должини. Соодветно на тоа, сите добиени спектри мора да бидат коригирани за овие ефекти за да се обезбеди нивната точност и кохерентност со реалните услови во зоната на топење.

Техничките карактеристики на спектрометарот се прикажани во Табела 4-2.

Табела 4-2: Технички карактеристики на спектрометарот Avantes 2048 USB2

Параметар	Вредност
Опсег на бранови должини [nm]	200 – 1100
Фокусна должина [mm]	75
Решетка [линии/mm]	1200
Ширина на процеп [μm]	50
Резолуција [nm]	0.546
Однос меѓу сигнал и шум	200:1
Минимално време на интеграција [ms]	1.1
Брзија на семплирање со вградена пресметка на средна вредност [ms/скен]	1.11
Брзина на пренос на податоци [ms/скен]	1.8


4.3. Развој и имплементација на мониторинг систем за оптичка емисиона спектроскопија на LPBF машина

За да се постигнат целите на истражувањето, беше развиен мониторинг систем за оптичка емисиона спектроскопија при што LPBF платформата беше опремена со коаксијален спектрометар за да се снима рефлектираната емисија за време на процесот. Сензорот е поставен во оптичкиот ланец на ласерот за мониторинг, овозможувајќи директно набљудување на зоната на интеракција помеѓу ласерот и материјалот преку главата за скенирање и собирање на податоци од емисијата од зоната на топење без мешање со други извори на светлина. Поставувањето на

сензорот на овој начин е карактеризирано со подвижна референтна рамка која овозможува конзистентно следење на емисијата од зоната на топење, овозможувајќи мониторинг на процесот во реално време. Шематски приказ на коаксијалната имплементација на сензорот како и фотографија од физичкиот систем е прикажано на Слика 4.5.

За да се обезбеди кохерентност помеѓу добиениот сигнал и тековниот експериментален процес за целите на докторското истражување, управувањето на спектрометарот е поврзано со контролната картичка на LPBF машината. Аквизицијата на спектрометарот е поставено да се активира автоматски преку контролната картичка на LPBF машината, обезбедувајќи собирањето на податоците да започне истовремено со почетокот на ласерската емисија и усогласеност на добиените спектрални информации со процесот на ласерско топење.

За време на сите експерименти, времето на интеграција на спектрометарот е фиксирано на 10 ms. Ова време е избрано за да биде подолго од најдолгото времетраење на ласерскиот пулс кој е користен во експериментите, со цел да се опфати целата емисија што произлегува од процесот и сите спектрални информации генерирани во текот на секој пулс на ласерот.




Слика 4.5: Коаксијална имплементација на сензорот: а) шематски приказ; б) фотографија од физичкиот систем

Дополнително, за да се процени кривата на преносливост на оптичкиот ланец на LPBF системот, беше развиена и имплементирана и конфигурација на мониторинг системот надвор од оптичкиот пат на ласерот. Во оваа конфигурација, спектрометарскиот сензор беше поставен надвор од оптичката патека на ласерот,

ориентиран под специфичен агол за набљудување на дефинирана зона од интерес над слојот од прав, каде што се одвива интеракцијата помеѓу ласерот и материјалот. Податоците добиени од вака поставениот сензор не се под влијание од карактеристиките на преносливост и загуби на оптичките елементи во главата на скенирање, и со тоа емисијата може да се анализира во нејзината оригинална форма. Но и покрај оваа предност, овој пристап не е погоден за мониторинг во реално време на процесот бидејќи сензорот е насочен кон фиксна и ограничена зона од интерес на работната површина и не го следи движењето на ласерот и зоната на топење, што е клучно за континуиран мониторинг на процесот. Дополнително, сензорот регистрира околна светлина во брановите должини што може да ги детектира и обезбедува интегриран излез кој ги комбинира околната и процесната светлина.

Шематски приказ на имплементацијата на сензорот надвор од оптичкиот пат како и фотографија од физичкиот систем е прикажано на Слика 4.6.



Слика 4.6: Имплементација на сензорот надвор од оптичкиот пат на ласерот: а) шематски приказ; б) фотографија од физичкиот систем

Во двете конфигурации, спектрометарот е позициониран надвор од комората за печатење, при што коаксијално има имплементирано оптичко влакно кое служи како медиум за пренос на емисијата од зоната на интеракција до спектрометарот. Беа дизајнирани специјализирани стезни прибори за да се обезбеди стабилноста на оптичкото влакно за време на мониторингот, робустно и точно следење на емисијата од процесот, како и за заштита на влакното од потенцијални оштетувања. Во рамките на држачот, пред оптичкото влакно, монтиран е кратко-пропусен филтер (FESH1000, Thorlabs Inc, USA) за да ги блокира емисионите бранови должини над 1000 nm, со цел да ја ублажи потенцијалната штета и заситувањето на сигналот што

може да ја предизвика повратната рефлексија на брановата должина на ласерската емисија од 1070 nm. Аквизицијата на спектрометарот е синхронизирана да започне по иницирањето на ласерската емисија за усогласување на собирањето на податоците со процесот на обработка, овозможено преку доставување на стартен тригер до спектрометарот од контролната картичка на ласерот.

4.3.1. Определување на кривата на преносливост на оптичките компоненти

За да се процени ефектот на оптичките елементи во главата за скенирање врз интензитетот на емисионите спектри и да се определи кривата на преносливост на оптичката патека на ласерот која служи за калибрација на системот, беше спроведен експеримент кој опфаќа споредба на спектарот на оптичката емисија добиен со коаксијалната конфигурација на сензорот и оној добиен со конфигурацијата надвор од оптичкиот пат.

Ласерски пулс со $P = 200\text{ W}$ и $t_{on} = 800\text{ }\mu\text{s}$ беше насочен кон цврста плоча од AISI316L, а емисијата од процесот е прво снимана со конфигурацијата на сензорот надвор од оптичкиот пат на ласерот, а потоа со коаксијалната конфигурација. Емисионите спектри се снимени во спектрален опсег од 400 до 900 nm. Со резолуцијата на сензорот од 0.546 nm, регистрирани се вкупно 884 бранови должини, при што секоја бранова должина има соодветен интензитет.

Кривата на преносливост е проценета со квантитативно оценување на разликите во интензитетите на емисиите помеѓу двете конфигурации кои се должат на загубите на пропустливост предизвикани од оптичките компоненти во ласерската оптичка патека, според следната равенка:

$$T(\lambda_i) = \frac{I_{coaxial}(\lambda_i)}{I_{off-axial}(\lambda_i)} \quad (4-1)$$


каде:

- λ_i каде $i = 1: 884$ се брановите должини во опсег од 400 до 900 nm,
- $I_{coaxial}(\lambda_i)$ е интензитетот на емисиониот спектар за брановата должина λ_i добиен од сензорот поставен коаксијално,
- $I_{off-axial}(\lambda_i)$ е интензитетот на емисиониот спектар за брановата должина λ_i добиен од сензорот поставен надвор од оптичкиот пат,
- $T(\lambda_i)$ е вредноста на кривата на преносливост за брановата должина λ_i .

Добиената крива на преносливост е користена во сите следни експерименти, овозможувајќи трансформација на директните емисии снимени со коаксијалната конфигурација во коригирани спектри $I_{corrected}(\lambda_i)$, обезбедувајќи усогласеност на добиените спектрални информации со обработуваниот материјал, преку следната равенка:

$$I_{corrected}(\lambda_i) = \frac{I_{coaxial}(\lambda_i)}{T(\lambda_i)} \quad (4-2)$$

Споредбите на спектрите добиени со коаксијалната конфигурација на сензорот и конфигурацијата надвор од оптичкиот пат се прикажани на Слика 4.7.



Слика 4.7: Споредба на спектрите на AISI316L добиени со коаксијалната конфигурација на сензорот и конфигурацијата надвор од оптичкиот пат при $P = 200 \text{ W}$ и $t_{on} = 800 \mu\text{s}$, користени за проценка на кривата на преносливост на оптичките елементи

4.4. Заклучоци за поглавјето

Во ова поглавје е опишана конфигурацијата на експерименталната опрема за реализација на истражувањето. Развиен и имплементиран е мониторинг систем базиран на оптичка емисиона спектроскопија, овозможувајќи in-situ следење и анализа на процесот. Заклучоците од ова поглавје се следните:

- Експериментите се спроведени на отворена LPBF платформа во лабораторијата SITEC при Politecnico di Milano, Милано, Италија, со ласер IPG Photonics YLR-300-AC-Y11 (300 W, $\lambda = 1070 \text{ nm}$, CW/PW режим). Управувањето со ласерот и скенирањето е реализирано преку AM Module v1.1 (Raylase) со коаксијална мониторинг линија и SP-ICE III контролна картичка. За дефинирање на стратегии и параметри е користен софтвер Direct

Machining Control. Главата на скенирање содржи оптичка патека со колимирачка единица, проширувач, фокусен систем, галванометриски огледала и дихроично огледало за раздвојување на ласерската и емисионата светлина.

- За целите на истражувањето, развиен е мониторинг систем за оптичка емисиона спектроскопија со Avantes 2048 USB2 спектрометар (200–1100 nm, 0.546 nm резолуција) и оптичко влакно со FESH1000 кратко-пропусен филтер за елиминација на заситување од брановата должина на ласерот од 1070 nm. Сензорот е поставен во оптичкиот ланец за директно следење на интеракцијата помеѓу ласерот и материјалот и собирање податоци од зоната на топење.
- Развиена и имплементирана е и мониторинг конфигурација надвор од оптичкиот пат за проценување на кривата на преносливост на оптичкиот ланец. Креиран е експериментален протокол за калибрација и добивање на коригирани спектри во опсег на бранови должини од 400 до 900 nm за понатамошна анализа според односот на емисионите спектри добиени со коаксијална и конфигурација надвор од оптичкиот пат.
- Направена е синхронизација на спектрометарот со контролната картичка на LPBF машината, овозможувајќи автоматско стартување на аквизицијата на спектрометарот и усогласено собирање на податоци со почетокот на ласерската емисија.

5. ЕКСПЕРИМЕНТИ И РЕЗУЛТАТИ

Ова поглавје опфаќа дефинирање и спроведување на експерименти и обработка на добиените резултати со цел верификација на имплементираниот мониторинг систем и собирање податоци за понатамошната анализа.

Најпрво е дефиниран експериментален план согласно целите на истражувањето, при што се дефинирани фиксните и променливите фактори како и нивните нивоа.

Во текот на спроведувањето на експериментот, сензорот за оптичка емисиона спектроскопија е поставен коаксијално во оптичкиот пат, со што се собрани емисиони спектри од зоната на топење при интеракција помеѓу ласерскиот зрак и материјалот за време на печатењето.

Потоа се прикажани резултатите од експериментите. Прво се презентирани мерењата на дијаметарите на стопените региони, проследени со статистичка анализа за утврдување на зависноста од варијациите на факторите. Потоа се покажани примери од емисиони спектри, и направена е нивна статистичка анализа во функција од променливите фактори.

Добиените резултати потврдуваат дека мониторинг системот е успешно интегриран на LPBF машината и е способен да детектира промени во условите на процесот, што овозможува понатамошна употреба на спектралните податоци за следење и толкување на клучни процесни карактеристики.

5.1. План и спроведување на експериментите

Планот на експериментите е креиран со цел да се соберат сите потребни податоци за анализа и моделирање на претходно споменатите фактори на следење на квалитетот на процесот, користејќи информации од спектралната емисија. За време на овој експеримент беше користена коаксијалната конфигурација на сензорот за мониторинг, која овозможуваше директно следење на зоната на топење.

Планот на експериментот се базира на стратегија на единечна точка на изложеност на ласерот (SPE) на еден слој метален прав. Како што беше споменато, земајќи ги предвид типичните времиња на доцнење и на пораст на ласерскиот пулс на комерцијалните ласерски извори со оптичко влакно кои емитираат во конитуиран режим (CW), обликот на единечниот пулс може да се апроксимира со квадратен облик каде моќноста P е достигната моќност на ласерска емисија во времетраење од времето на изложеност на ласерот еднакво на t_{on} [185].

Конвенционалните CW фибер ласерски извори се контролираат преку аналогни и дигитални сигнали, каде што P се поставува преку аналогниот канал, додека t_{on} се постигнува со модулација на ласерот преку дигиталниот канал. Енергетскиот внес E [J] на ласерот се пресметува како функција од моќноста и времето на изложеност според равенката:

$$E [J] = P \cdot t_{on} \quad (5-1)$$

Параметрите на пулсот и резултантниот енергетски внес има значително влијание врз динамиката на топење за време на процесот [186]. Како резултат на ласерскиот пулс се формира зона на топење со кружен облик со одреден дијаметар. Енергетскиот влез, како и кај конвенционалните стратегии, треба да биде оптимизиран за да обезбеди доволна енергија за топење на материјалот, но истовремено да се избегне прекумерно прегревање и испарување на материјалот. Оваа прецизна контрола на енергетските параметри е од суштинско значење за постигнување на висококвалитетни резултати и за избегнување на појава на дефекти во производот.

Експериментите беа спроведени на металните легури AISI316L и Ti-6Al-4V поради нивната широка примена и популарност како едни од најчесто користените материјали за изработка на решеткасти структури со адитивно производство. Овие материјали наоѓаат широка примена во индустрии како што се воздухопловството, биомедицината, автомобилската индустрија и енергетскиот сектор [187].

Стратегијата SPE на испитуваните материјали е веќе применета во научни истражувања, каде е покажано дека нејзината примена резултира со значително намалување на дефектите во критичните геометрии на изработените делови [103], и

дека со нејзина примена може да се оптимизира процесот на печатење на сложени геометрии.

За да се истражи феноменот на денудација и неговите спектрални карактеристики, експериментите беа спроведени користејќи прашкасти и цврсти форми од истиот тип на материјал. Овој пристап овозможи анализа на разликите во спектралните информации во присуство на прав наспроти негово отсуство, со што се “симулираше” појавата на денудација.

Хемискиот состав на испитуваните метални легури се прикажани во Табела 5-1 за AISI316L и Табела 5-2 за Ti-6Al-4V. Во склоп на истражувањето, овие податоци се важни за интерпретацијата на спектралните мерења и отчитување на спектралните емисиони мапи кои се добија во експериментите во функција од легирачките елементи во материјалите.

Табела 5-1: Хемиски состав на металната легура AISI316L

Хемиски елемент	C	Mn	Si	P	S	Cr	Ni	Mo	Fe
Состав (wt%)	≤ 0.03	≤ 2.00	≤ 1.00	≤ 0.05	≤ 0.02	16.50- 18.50	10.00- 13.00	2.00- 2.50	Баланс

Табела 5-2: Хемиски состав на металната легура Ti-6Al-4V

Хемиски елемент	Ti	Al	V	Fe	O	C	N	H
Состав (wt%)	Баланс	5.50- 6.75	3.50- 4.50	≤ 0.40	≤ 0.20	≤ 0.08	≤ 0.05	≤ 0.015


Беше направен експеримент со четири променливи фактори, од кои два нумерички и два атрибутивни. Двата атрибутивни фактори се типот на материјал кој се менува на две нивоа (AISI316L и Ti-6Al-4V) и состојбата на материјалот на две нивоа (прашката состојба и полн материјал). Нумеричките фактори се моќноста на ласерот (P) и времето на изложеност на ласерот (t_{on}) кои се менуваат на три различни нивоа (ниско, средно и високо ниво) со вредностите на нивоата прикажани на Табела 5-3. Експериментите беа спроведени за сите комбинации од нивоата на сите фактори. Како помошен инертен гас, во сите експерименти се користи аргон со притисок од 1 бар. Опсегот на параметрите беше утврден преку претходно тестирање на материјалите. За да се обезбеди статистичка значајност на резултатите, секој експеримент во полн материјал беше повторен 3 пати, додека експериментите

со прав беа повторени 12 пати, резултирајќи со вкупно 270 експерименти земајќи ги во предвид двата материјали.

Фиксните и променливите фактори и нивните нивоа применети во експериментите се сумирани во Табела 5-3. Шематски приказ на експерименталниот тек во различните фази на LPBF процесот е даден на Слика 5.1.

Табела 5-3: Фиксни и променливи фактори со нивните нивоа во експерименталниот план

Фиксни фактори	Вредности
Стратегија на скенирање	SPE
Помошен гас	Ar
Притисок на помошен гас [bar]	1
Време на интеграција на сензорот [ms]	10
Променливи фактори	Вредности
Материјал	AISI316L, Ti-6Al-4V
Состојба на материјал	прашката состојба / полн материјал
Моќност на ласерот [W]	100 - 150 - 200
Време на изложеност на ласерот [μ s]	200 - 400 - 800



Слика 5.1: Шематски приказ на експерименталниот тек во различните фази на LPBF процесот

5.2. Мерење на дијаметрите на стопениот регион добиени од експериментите

Мерењето на големината на зацврстениот регион овозможува утврдување на дијаметарот на тенките столбови од решеткастата структура добиен со одреден енергетски влез на ласерот на специфичната локација која се следи во рамките на структурата. Ова мерење овозможува оценка на отстапувањето помеѓу постигнатиот дијаметар на столбовите и номиналниот дијаметар кој е дизајниран за изградбата на структурата.

За таа цел, дијаметрите на областите изложени на ласерско зрачење, кои резултираа со топење и промена на состојбата на материјалот во експерименталните примероци, беа снимени со употреба на оптички микроскоп (Echo-LAB SM 535 H, DEVCO S.r.l.) со резолуција од $5\text{ }\mu\text{m}$ и видно поле од $230\text{ mm} \times 170\text{ mm}$. Потоа, дијаметарот беше автоматски проценет со алгоритам изработен во софтверот MATLAB (The MathWorks, Inc., Massachusetts, САД). Алгоритамот најпрво ја идентификува најголемата внатрешно впишана кружница на зоната на топење, а потоа го пресметува нејзиниот дијаметар. Овој автоматизиран метод за мерење ја намалува можноста за човечка грешка и ја елиминира грешката од залепените честички прав на обемот на зоната на топење.

Условите каде енергетскиот влез на ласерот е под граничната вредност на енергија потребна за генерирање на стопен регион или за лепење на стопената материја со основната плоча се исклучени од понатамошните анализи, бидејќи не придонесуваат кон значајни резултати во понатамошната анализа.

На Табела 5-4 и Табела 5-5 се илустрирани примери од микроскопски слики на стопените региони за двата типа на материјал во двете состојби од експериментите со $t_{on} = 200\text{ }\mu\text{s}$ и $t_{on} = 800\text{ }\mu\text{s}$ при константно $P = 200\text{ W}$. Примерите ги прикажуваат разликите што произлегуваат од различните нивоа на енергетски влез.


Интуитивно, се забележува дека големината на стопениот регион директно зависи од параметрите на енергетскиот влез на ласерот. Со намалување на енергетскиот влез преку намалување на времето на изложеност на ласерот се забележува значително намалување на дијаметарот на стопениот регион. Овие резултати укажуваат дека големината на столбовите на решеткастата структура може да се контролира преку манипулација со енергетскиот влез, овозможувајќи оптимизација на процесот за специфични дизајнерски барања.

За промената на димензиите на стопениот регион во зависност од печатењето со исти параметри во присуство и отсуство на прав е тешко да се изведе директен заклучок само врз основа на визуелна инспекција. Присуството на прав влијае врз

апсорпцијата на ласерската енергија и топлотната динамика во регионот, што може да резултира со различни геометрии на топениот регион. Како резултат на тоа, анализата на врската помеѓу дијаметарот на стопениот регион и присуството/отсуството на прав бара понатамошна анализа за да се изведе заклучок.


Дополнително, може да се забележи дека дијаметарот на стопениот регион е поголем кај Ti-6Al-4V во споредба со AISI316L при исти енергетски параметри, што е соодветно на термичките својства на овие материјали. Ti-6Al-4V има понизок коефициент на топлинска спроводливост и поголема способност за апсорпција на енергијата на ласерската бранова должина во споредба со AISI316L, што резултира со помал пренос на топлина надвор од зоната на топење. Како резултат на тоа, повеќе енергија останува концентрирана во топениот регион, што води до поголем дијаметар на истиот.

Табела 5-4: Микроскопски слики на стопените региони за двата материјали во двете состојби добиени од експериментите со $P=200W$ и $t_{on}=200\mu s$

		Состојба на материјал	
		прашката	полн материјал
Тип на материјал	AISI316L		
	Ti-6Al-4V		

200um
└──────────┘

Табела 5-5: Микроскопски слики на стопените региони за двата материјали во двете состојби добиени од експериментите со $P=200W$ и $t_{on}=800\mu s$

		Состојба на материјал	
		прашката	полн материјал
Тип на материјал	AISI316L		
	Ti-6Al-4V		

200um
└──────────┘

5.2.1. Статистичка анализа на дијаметрите на стопениот регион

Слика 5.2 ги прикажува дијаграмите на интервали со 95% интервал на доверба на средната вредност на секоја група дијаметри на стопен регион (d_{melt}) измерени во микрометри [μm], добиени при обработка во присуство и отсуство на прав, како функција од параметрите P и t_{on} .

Дијаграмите на интервали се користат како визуелен метод за прикажување на варијацијата на податоците помеѓу групите и за проценка на доверливоста на средните вредности во рамките на дадено множество на податоци. Централната точка на секоја група го прикажува просекот на податоците за конкретната група на податоци; во овој случај, просекот на дијаметрите на стопениот регион добиени со соодветната комбинација на параметри. Линиите околу средната вредност претставуваат 95% интервали на доверба, кои го покажуваат опсегот во кој со 95% сигурност се очекува да се наоѓа вистинската вредност на параметарот што се разгледува. На дијаграмот на интервали на Слика 5.2 се гледа потесен интервал што укажува на помала варијација во групите и поголема сигурност во резултатите. Исто така, бидејќи интервалите на доверба помеѓу групите генерално не се поклопуваат, укажува на статистички значајна разлика помеѓу тие групи. Интервалот на доверба CI се пресметува според следната релација:

$$CI = \bar{x} \pm z \cdot \frac{s}{\sqrt{n}} \quad (5-2)$$


каде што $\bar{x}$ е средната вредност на податоците, z е вредност која е во функција од нивото на интервалот на доверба (за пресметка на интервал на доверба од 95% вредноста на z е еднаква на 1.960), s е стандардната девијација на податоците, а n е вкупниот број на податоци. Средната вредности и стандардната девијација на податоците се пресметуваат според следните релации:

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (5-3)$$

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n - 1}} \quad (5-4)$$

На дијаграмот може да се забележи дека за одредени комбинации на параметри не се прикажани измерени дијаметри на стопен регион. Ова е затоа што за тие комбинации влезната ласерска енергија не е доволна за да предизвика топење или

кога стопениот материјал не се прилепува за подлогата, со што не се создаваат мерливи области.



Слика 5.2: Дијаграми на интервали со 95% интервал на доверба на дијаметрите на стопените региони (d_{melt})

Понатаму, во случајот со Ti-6Al-4V, на Слика 5.2 може да се забележи дека при низок енергетски влез ($P = 100W$, $t_{on} = 200\mu s$ и $t_{on} = 400\mu s$), се јавува топење во отсуство на прав, но не и кога материјалот е во прашкаста состојба. Оваа појава може да се објасни со фактот дека правот апсорбира повеќе топлина во споредба со цврстиот материјал и енергетскиот влез е недоволен за да ја спои стопената фаза со цврстата подлога. Во случајот на AISI316L, нема услов кој завршил без топење на материјалот. Од ова може да се заклучи дека за да почне да се топи Ti-6Al-4V треба повеќе енергија заради повисоката точка на топење во однос на AISI316L (точка на топење на AISI316L е $\sim 1400\text{ }^{\circ}\text{C}$, а на Ti-6Al-4V е $\sim 1660\text{ }^{\circ}\text{C}$), но штом почне да се топи, заради понискиот коефициент на топлинска спроводливост и поголемата способност за апсорпција на енергијата на ласерската бранова должина (коефициент на топлинска спроводливост на AISI316L е $\sim 16\text{ W/m}\cdot\text{K}$, а на Ti-6Al-4V е $\sim 6.7\text{ W/m}\cdot\text{K}$), резултира со поголеми дијаметри на стопен регион за истата влезна енергија споредбено со AISI316L. Дополнително, на сликата може да се види дека интервалите на доверба на доверба односно варијацијата во податоците е поголема кај Ti-6Al-4V отколку кај AISI316L. Оваа појава се должи на понискиот коефициент на топлинска спроводливост кај титаниумската легура кој предизвикува локализирано акумулирање на топлина, како и различната микроструктурна реакција при рекристализација бидејќи AISI316L има стабилна аустенитна структура која е постабилна при термички влијанија.

Дисперзиона анализа (Analysis of variance – ANOVA [188]) е искористена за да се истражи статистичката значајност на факторите P , t_{on} , тип на материјал, и состојба на материјал, врз дијаметарот на стопениот регион (d_{melt}). Резултатите од анализата се сумирани во Табела 5-6. Р-вредноста е заокружена до трета децимала.

Табела 5-6: Резултати од дисперзионата анализа на влијанието на факторите врз дијаметарот на стопениот регион (d_{melt})

Извор	Степени на слобода (DF)	Сума на квадрати (SS)	F-вредност	P-вредност
$t_{on}[\mu s]$	2	336932	448.55	0.000
$P [W]$	2	110110	146.59	0.000
тип на материјал	1	164440	437.83	0.000
состојба на материјал	1	19119	50.91	0.000

Анализата покажува дека сите испитувани фактори имаат статистички значајно влијание врз разгледуваната променлива, при што Р-вредностите за секој фактор се помали од избраното ниво на значајност ($\alpha = 0.05$). Ова укажува дека постои

доволно статистичка основа за да се одбие нултата хипотеза и да се потврди дека влијанието на факторите врз променливата е значајно.

Параметарот t_{on} има најголем придонес во варијацијата на дијаметарот, со степен на слобода (DF) од 2, сума на квадрати (SS) од 336932 и F-вредност од 448.55. Ова укажува дека времето на изложеност е клучен параметар што директно влијае на дијаметарот на стопениот регион. Моќноста на ласерот (P) исто така има значајно влијание, со DF од 2, SS од 110110, и F-вредност од 146.59, што го прави вториот најзначаен фактор во експериментот.

Материјалот, како фактор, има DF од 1, SS од 164440, и F-вредност од 437.83, што покажува дека видот на материјалот (AISI316L или Ti-6Al-4V) игра клучна улога во дефинирањето на дијаметарот на стопените точки. Состојбата на материјалот (прашката состојба или полн материјал) има DF од 1, SS од 19119, и F-вредност од 50.91, што иако е помало во споредба со другите фактори, сепак претставува значаен параметар што влијае на резултатите.

Овие резултати покажуваат дека сите четири фактори се статистички значајни во дефинирањето на дијаметарот на стопениот регион, при што времето на изложеност и материјалот се најзначајните фактори.


Дополнително, графикот на поединечните влијанија на факторите врз одзивот, прикажан на Слика 5.3, покажува како секој фактор поединечно влијае на d_{melt} . За параметарот t_{on} , јасно се забележува дека со зголемување на времето на изложеност од 200 μs до 800 μs , значително се зголемува дијаметарот на стопениот регион. Ова покажува дека подолгото време на изложеност на ласерот овозможува поголем енергетски влез, што резултира со поголеми топени региони.

Слично, моќноста на ласерот P покажува позитивна корелација со d_{melt} . Со зголемување на моќноста од 100 W до 200 W, средниот дијаметар на стопените региони се зголемува.

Во однос на материјалот, Ti-6Al-4V има значително поголем дијаметар на стопените точки во споредба со AISI316L, што може да се припише на различните физички својства на материјалите, како што се понискиот коефициент на топлинска спроводливост и поголемата способност за апсорпција на енергијата на ласерската бранова должина кај Ti-6Al-4V.


Конечно, состојбата на материјалот исто така има значајно влијание. Средниот дијаметар на стопените региони е поголем кога материјалот е во форма на прав во споредба со кога топењето е во полн материјал. Ова може да се објасни со фактот дека металниот прав има пониска топлинска спроводливост во споредба со цврстиот материјал. Пониската топлинска спроводливост на правот овозможува акумулирање на повеќе енергија во зоната на топење, наместо да се дисперзира топлината низ

материјалот. Како резултат на тоа, зоната на топење станува поголема, што доведува до зголемување на дијаметарот на стопените точки.



Слика 5.3: График на поединечните влијанија на факторите врз дијаметрите на стопените региони (d_{melt})

На Слика 5.4 е претставен график каде што се гледаат влијанијата на меѓусебните интеракции на факторите врз дијаметарот на стопениот регион d_{melt} . Врз основа на непаралелните линии, од графици се забележува дека постои интеракција меѓу факторите. Ова укажува дека односот меѓу факторите не е линеарен, освен во случајот на интеракцијата помеѓу t_{on} и состојбата на материјалот каде линиите имаат тенденција на паралелност.



Слика 5.4: График на влијанијата на меѓусебните интеракции на факторите врз дијаметарот на стопениот регион d_{melt}

5.3. Анализа на емисионите спектри од коаксијалниот мониторинг на процесот


При спроведување на експериментите, коаксијалниот мониторинг систем собираще спектрални податоци за време на процесот. Слика 5.5 прикажува по еден пример од емисионите спектри за различните материјали и нивната состојба како функција од времето на изложеност на ласерот, при константна моќност на ласерот од 200 W. Слика 5.6 прикажува примери од емисионите спектри како функција од моќноста на ласерот, при константно време на изложеност од 400 μs . Прикажаните спектри претставуваат емисии директно добиени од сензорот кои не се коригирани со претходно утврдената крива на пропустливост на оптичкиот ланец на ласерот во главата на скенирање. Кај двата метали AISI316L и Ti-6Al-4V се забележува јасен тренд: со зголемување на енергетскиот влез, се јавува соодветно зголемување на интензитетот на спектралната емисија и во видливиот (VIS) и во блискиот инфрацрвен (NIR) регион на бранови должини. Ова укажува дека повисоката енергија доведува до поголемо возбуждување на електроните во материјалот, што резултира со повисок интензитет на емисија.

Формата на емисиониот спектар е различен за различните материјали, со различни спектрални екстрими во рамките на разгледуваните бранови должини. Овие


екстреми соодветствуваат на легирачките елементи кои се присутни во металните легури, како што се документирани во базата на податоци на Националниот институт за стандарди и технологија (National Institute of Standards and Technology - NIST Atomic Spectra Database) [133].

Секој елемент во составот на металната легура е поврзан со спектрален екстрем на специфични бранови должини, што е резултат на енергијата што се ослободува кога електроните преминуваат од едно енергетско ниво на друго. Овие транзиции се уникатни за секој елемент бидејќи енергетските нивоа и интервалите меѓу нив се карактеристични за секој атом, како што е детално објаснето во Поглавје 3.5. Како резултат на тоа, спектарот што се добива за секој материјал може да се смета за негов уникатен "отпечаток" кој ја отсликува неговата хемиска композиција. Овој отпечаток овозможува идентификација на присутните елементи и анализа на нивните концентрации во легурата. Преку споредување на спектралните екстреми со референтните вредности од NIST базата на податоци, може да се идентификуваат легирачките елементи во материјалот. Ова е од особено значење за разбирање на хемиските својства на материјалите и нивното однесување за време на процесот на ласерско топење или друга термичка обработка. Детално објаснување и анализа на формата на емисионите спектри, како и изведените карактеристики поврзани со нив, се презентирани и објаснети во Поглавје 7.

На сликите Слика 5.5 и Слика 5.6 може да се види дека Ti-6Al-4V покажува многу поголем интензитет на спектрална емисија во споредба со AISI316L при исти влезни параметри. Ова е резултат на тоа што Ti-6Al-4V повеќе “зрачи”, има поголема способност за апсорпција на енергијата на ласерската бранова должина и емитира повеќе светлина при топењето, како и затоа што елементите од кои се состои Ti-6Al-4V, особено титаниумот, емитуваат посилен светлосен сигнал кога се загреани во споредба со железото, хромот и никелот присутни кај AISI316L.




Слика 5.5: Примери и споредба на емисионите спектри за двата материјали и двете состојби како функција од времето на изложеност на ласерот t_{on} при константна моќност $P = 200 W$



Слика 5.6: Примери и споредба на емисионите спектри за двата материјали и двете состојби како функција од моќноста на ласерот P при константно време на изложеност $t_{on} = 400 \mu s$

На Слика 5.7 е прикажана споредба помеѓу необработените и коригираните спектри калибрирани со примена на кривата на преносливост, за двата материјали во прашкаста состојба, добиени од експериментите со $P = 200\text{ W}$ и $t_{on} = 800\text{ }\mu\text{s}$. Емисиониот спектар за секој материјал има карактеристична форма и спектрални линии во опсегот на преносливите бранови должини. Овие линии соодветствуваат со легирачките елементи на соодветните материјали [133]. Идентификуваните спектрални екстрими се означени на Слика 5.7 на нивните соодветни бранови должини во добиените спектри. Деталната анализа на спектрите и спектралните екстрими за сите експериментални податоци е дадена во Поглавје 7.3.



Слика 5.7: Споредба меѓу некоригирани и коригирани спектри со примена на крива на преносливост за двата материјали при $P = 200\text{ W}$ и $t_{on} = 800\text{ }\mu\text{s}$, со означени спектрални екстрими на легирачките елементи според базата на NIST [133]

5.3.1. Статистичка анализа на спектралните податоци

За да се анализира влијанието на факторите врз спектралната емисија, анализирани се средната вредност и стандардната девијација одделно на интензитетите на спектралната емисија во два опсези на бранова должина:

- VIS опсег – опсег на видливиот спектрален регион (400 – 780 nm)
- NIR опсег – опсег на блиско-инфрацрвениот спектрален регион (780 – 900 nm, иако NIR опсегот е до 2500 nm но ограничувањето е заради преносливоста на оптичките елементи во оптичкиот пат).

Со оваа поделба се овозможува споредба на спектралните карактеристики на емисиите во различни делови од спектарот. Експериментите покажаа статистички значајно влијание на факторите t_{on} , P , тип на материјал, и состојба на материјал врз интензитетот на спектралната емисија, што беше потврдено преку дисперзиона анализа (ANOVA) прикажана во Табела 5-7. Р-вредноста е заокружена до трета децимала. Испитуваните параметри се средната вредност (μ) и стандардната девијација (σ) на интензитетите на емисијата во VIS и NIR опсег на бранови должини. Средната вредност го претставува просечниот интензитет на емисијата во дадениот спектрален опсег (λ_1 до λ_2) и се пресметува како:

$$\mu = \frac{1}{N} \sum_{i=1}^N I(\lambda_i) \quad (5-5)$$

каде што:

- N е вкупниот број на бранови должини во анализираниот опсег (VIS или NIR),
- $I(\lambda_i)$ е интензитетот на емисијата за одредена бранова должина λ_i .

Стандардната девијација ја покажува распределбата на интензитетите околу средната вредност и се пресметува како:

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (I(\lambda_i) - \mu)^2} \quad (5-6)$$

каде што:

- $I(\lambda_i)$ е интензитетот на емисијата за одредена бранова должина λ_i ,
- N е вкупниот број на бранови должини во анализираниот опсег (VIS или NIR),
- μ е средната вредност на интензитетите во дадениот опсег.


Табела 5-7: Резултати од дисперзионата анализа на влијанието на факторите врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини

Опсег на бранови должини	Параметар	Извор	F-вредност	P-вредност
VIS	μ	t_{on}	78.01	0.000
		P	22.55	0.000
		тип на материјал	307.92	0.000
		состојба на материјал	6.29	0.013
	σ	t_{on}	77.50	0.000
		P	20.49	0.000
		тип на материјал	306.51	0.000
		состојба на материјал	6.88	0.009
NIR	μ	t_{on}	96.20	0.000
		P	33.52	0.000
		тип на материјал	293.38	0.000
		состојба на материјал	18.88	0.000
	σ	t_{on}	108.96	0.000
		P	36.08	0.000
		тип на материјал	354.21	0.000
		состојба на материјал	0.24	0.627


Во ANOVA табелата (Табела 5-7), високите F-вредности и P-вредностите под прагот на значајност ($\alpha = 0.05$) покажуваат дека сите фактори имаат статистички значајно влијание врз варијациите на спектрите во двата опсези на бранови должини. Високите F-вредности укажуваат на тоа дека варијациите предизвикани од овие фактори значително ги надминуваат варијациите предизвикани од грешката, потврдувајќи ја нивната релевантност во процесот. Се забележува дека единствено состојбата на материјалот нема статистички значајно влијание врз стандардната девијација на интензитетите во NIR опсегот, бидејќи P-вредноста е над $\alpha = 0.05$. Сепак, состојбата на материјалот покажува статистички значајно влијание врз средната вредност на интензитетите во истиот спектрален опсег.

За да се анализира влијанието на факторите P и t_{on} врз μ и σ на емисионите спектри за различните бранови должини, граfiците на поединечни влијанија се прикажани во Табела 5-8 - Табела 5-11, во одделни табели за двата испитувани материјали во двете состојби.


Табела 5-8: График на поединечните влијанија на факторите P и t_{on} врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини кај AISI316L во прашката состојба




Табела 5-9: График на поединечните влијанија на факторите P и t_{on} врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини кај Ti-6Al-4V во прашката состојба



Табела 5-10: График на поединечните влијанија на факторите P и t_{on} врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини кај AISI316L - полн материјал



Табела 5-11: График на поединечните влијанија на факторите P и t_{on} врз средната вредност (μ) и стандардната девијација (σ) на интензитетите на спектралната емисија во VIS и NIR опсег на бранови должини кај Ti-6Al-4V - полн материјал



5.4. Заклучоци за поглавјето

Во ова поглавје е дефиниран експерименталниот план и се прикажани резултатите од собирањето на податоците со применетиот мониторинг систем за оптичка емисиона спектроскопија. Податоците се статистички обработени со цел валидирање на применливоста на развиениот мониторинг систем. Главните заклучоци од ова поглавје се следните:

- Спроведен е експеримент со примена на SPE стратегија на AISI316L и Ti-6Al-4V, во две состојби (прашката и полн материјал), со варијација на моќноста и времето на изложеност на ласерот на три нивоа, при инертна атмосфера, при што беа испитани сите можни комбинации од нивоата на сите фактори.
- Димензиите на стопените региони се снимени со оптички микроскоп и потоа е развиен алгоритам во MATLAB за автоматска проценка на дијаметарот, со цел елиминирање на човечка грешка и зголемена репродуктивност.
- Резултатите покажаа дека Ti-6Al-4V бара повисок енергетски влез за иницијално топење поради повисоката точка на топење (~ 1660 °C) во споредба со AISI316L (~ 1400 °C). Штом почне да се топи, Ti-6Al-4V резултира со поголеми дијаметри на стопениот регион поради пониската топлинска спроводливост (~ 6.7 W/m·K наспроти ~ 16 W/m·K кај AISI316L) и поголемата апсорптивност на енергијата на ласерската бранова должина.
- ANOVA анализата на резултатите покажа дека сите четири фактори (моќност на ласер, време на изложеност на ласер, материјал, состојба на материјал) имаат статистички значајно влијание врз дијаметарот на стопените региони (P -вредности < 0.05), при што времето на изложеност и материјалот се најзначајните фактори.
- Анализата на емисионите спектри добиени со мониторинг системот покажа корелација помеѓу енергетскиот влез и интензитетот на спектралната емисија. Спектрите имаат карактеристични екстреми кои соодветствуваат на легирачките елементи на материјалите, како што се наведени во NIST базата на податоци.
- Забележано е дека Ti-6Al-4V генерира значително посилен интензитет на спектрална емисија во споредба со AISI316L при исти влезни параметри. Ова е резултат на поголемата способност за апсорпција на енергијата на ласерската бранова должина на Ti-6Al-4V како и посилната светлосна емисија на легирачките елементи на Ti-6Al-4V, особено титаниумот.

- ANOVA анализата на спектралните податоци покажа дека сите фактори имаат статистички значајно влијание врз средната вредност и стандардната девијација на интензитетите на спектралната емисија во VIS и NIR опсегот на бранови должини, со исклучок на состојбата на материјалот за σ во NIR опсегот.
- Резултатите покажуваат дека сензорот за оптичка емисиона спектроскопија, имплементиран коаксијално на LPBF машината, обезбедува увид во процесот, овозможувајќи следење на неговите варијации предизвикани од промените на влезните параметри. Ова укажува дека употребата на OES мониторинг систем овозможува ефикасно следење на динамиката на процесот, која е директно под влијание на варијациите во енергетскиот влез.
- Преку испитување на интензитетите на емисијата станува возможно да се врши мониторинг на условите на обработка и потенцијалните дефекти во реално време, овозможувајќи преземање корективни акции кога ќе се забележат несоодветни услови на обработка доколку се додаде контрола со повратна врска. Сепак, важно е да се напомене дека ефикасноста на мониторингот во реално време е ограничена од фреквенцијата на аквизиција на сензорот. Оваа ограниченост може да влијае врз способноста за прецизно следење на брзите промени во процесот, што го прави неопходно дополнителното усовршување на сензорските и/или контролните системи за да се обезбеди поголема брзина и точност на мерењето.

6. РЕЗУЛТАТИ ОД ПРИМЕНАТА НА МОДЕЛИ СО МАШИНСКО УЧЕЊЕ ЗА МОНИТОРИНГ НА LPBF ПРОЦЕСОТ

Ова поглавје ги презентира резултатите од примената на модели со машинско учење за анализа на спектралните податоци добиени за време на LPBF процесот. На почеток е претставена методолошката рамка на предложениот пристап за имплементација на машинското учење во ова истражување.

Понатаму прикажан е развојот и имплементацијата на пет модели со машинско учење за класификација, наменети за препознавање на материјалот што се обработува и детекција на појава на денудација. За секој модел се прикажани резултатите според метрики за точност, како и споредбена анализа на брзината на предвидување.

Следно е покажана имплементацијата на пет модели со машинско учење за регресија, развиени за предвидување на дијаметарот на стопената зона во процесот на обработка. Нивната точност и брзина на предвидување се анализирани и споредени.


Дополнително, опфатени се резултати од ненадгледувано машинско учење преку анализа на главни компоненти, со цел добивање на релевантни информации за процесот преку намалување на димензионалноста на спектралните податоци.

Со овие резултати се потврдува дека со примена на OES мониторинг и модели со машинско учење може со висока точност да се предвидат дефекти и процесни карактеристики, што го покажува потенцијалот за интелигентно следење на LPBF процесот.

6.1. Методолошка рамка на предложеното истражување за имплементација на модели со машинско учење

Со цел да се развие методолошкиот рамковен пристап најпрво е потребно да се дефинираат истражуваните класи. Рамковниот модел се базира на спектралните податоци од мониторинг системот за оптичка емисиона спектроскопија (OES), дополнет со модели базирани на машинско учење, со цел да се овозможи континуирано следење на процесот и проценка во реално време на присуство/отсуство на прав, вид на материјалот и големината на стопениот регион.

Во ова истражување се анализираат два различни материјали, при што е клучно да се идентификува присуството или отсуството на прав. Согласно тоа, дефинирани се четири посебни класи дефинирани на Слика 6.1.



Слика 6.1: Дефинирање на четирите класи кои се применети во моделите со машинско учење

Оваа класификација претставува основа на методолошката рамка која е применета низ целото истражување за анализа и моделирање. Ваквиот пристап овозможува детално разбирање на процесните параметри и нивното влијание врз крајниот квалитет на изработените структури, што дополнително го поддржува развојот на автоматизирани системи за мониторинг и управување на процесот.

Предложената методолошка рамка е шематски претставена на Слика 6.2. Методологијата започнува со прибирање на директниот необработен спектар што се генерира од коаксијалниот спектрометар за време на ласерското скенирање со

стратегија на единечна точка на изложеност на соодветниот материјал. Овој директен спектар потоа се обработува за да се коригира со употреба на кривата на преносливост на оптичките елементи во ласерскиот оптички ланец. Корекцијата овозможува елиминирање на ефектите од преносливоста на елементите, со што се добива прецизен коригиран спектар кој ги рефлектира вистинските емисиони карактеристики на процесот.

Овој коригиран спектар потоа се користи како влез за класификацискиот модел на машинско учење, кој има задача да го идентификува типот на материјал што се обработува (AISI316L или Ti-6Al-4V) и да детектира дали има недостаток на прав врз слојот (дефект на денудација).

Предвидената класа заедно со коригираниот спектар се користат како влез во регресиониот модел на машинско учење, чија задача е да ја предвиди големината на топената зона предизвикана од ласерот, што соодветствува на дијаметарот на столбот во рамките на решеткестата структура кога тој е граден со SPE стратегија во LPBF. За време на анализата беше забележано дека регресиониот модел покажува значително повисока точност кога, покрај спектарот, како влез се користи и класификацијата на материјалот и состојбата. Ова дополнително ја подобрува точноста на моделирање и овозможува попрецизни резултати.


Во рамките на истражувањето се тестирани различни модели на машинско учење, кои вклучуваат надгледувани методи на машинско учење со класификација и регресија, за да се утврди кој од нив најдобро ја моделира корелацијата помеѓу спектралните податоци и карактеристиките на процесот. На крајот е избран моделот што покажува највисока точност и најдобра усогласеност со емпириските податоци, со што ќе се обезбеди солидна основа за реално-временски мониторинг и оптимизација на LPBF процесот.

Дополнително, идентификацијата на материјалот и состојбата (четирите класи) се спроведува и со примена на Анализа на главни компоненти (Principal Component Analysis - PCA), која претставува ненадгледуван метод на машинско учење. Целта на оваа анализа е да ја намали димензионалноста на влезните спектрални емисиони податоци, истовремено задржувајќи ги најзначајните карактеристики и информации кои се релевантни за идентификацијата на материјалот [132]. Со PCA, големите спектрални податоци се трансформираат во нов сет на променливи (главни компоненти), кои се линеарни комбинации на оригиналните податоци, рангирани според нивниот придонес во варијансата.

Овој пристап овозможува поефикасна анализа преку елиминирање на непотребните и незначајните информации, со што се намалува комплексноста на моделот а сепак се овозможува ефикасност во моделирањето на корелациите. На овој начин, точноста на моделот за идентификација на материјалот е тестирана со влезни

податоци од пониска димензија, но со задржани критични спектрални карактеристики кои ја разликуваат класификацијата на материјалите.

Со овој интегриран рамковен модел се поставуваат основите на интелигентен LPBF систем кој комбинира мониторинг во реално време преку OES сензор и алгоритми на машинско учење. Овој систем е дизајниран да ги следи и анализира состојбите на процесот, како и автономно да воочи појава на аномалии или дефекти. Способноста за самодијагностика и адаптивност е клучна за подобрување на ефикасноста и квалитетот на LPBF процесот, истовремено минимизирајќи ги дефектите и зголемувајќи ја продуктивноста. На крај, ваквиот пристап обезбедува основа за развој на идни автоматизирани и автономни производствени системи кои ќе бидат неразделно поврзани со дигиталната индустрија.




Слика 6.2: Методолошка рамка за примена на моделите со машинско учење во истражувањето


6.2. Применети техники за валидација на моделите и оптимизација на хиперпараметрите

За да се заштити моделот од прекумерно прилагодување на влезните податоци, беше користен методот на вкрстена валидација со 5 сегменти [189]. Ова е техника која се користи за оценување на перформансите на моделот со машинско учење, со цел да се намали ризикот од прекумерно прилагодување на податоците и да се добие реална слика за тоа како моделот ќе функционира на нови, претходно непознати податоци. Оваа метода работи со делење на целосната база на податоци на повеќе делови (во овој случај на пет) и обезбедува робустна проценка преку повеќекратно тестирање. Со користење на оваа техника за валидација на моделот се осигурува дека моделот добро генерализира на невидени податоци преку користење на различни делови од податочниот сет за тренирање и валидација во повеќе итерации.

Шематски приказ на принципот на работа на техниката на вкрстена валидација со 5 сегменти е дадено на Слика 6.3, додека чекорите на техниката како и нивното објаснување се дадени на Слика 6.4.



Слика 6.3: Шематски приказ на принципот на работа на техниката на вкрстена валидација со 5 сегменти кај моделите со машинско учење



Слика 6.4: Чекори на имплементација на техниката на вкрстена валидација со 5 сегменти кај моделите со машинско учење

Оваа техника е често применувана кај моделите за машинско учење бидејќи помага да се избегне прекумерното прилагодување на моделот кон влезните податоци. Со делењето на податоците на подмножества за тренирање и валидација, моделот не се прилагодува само на одреден дел од податоците, што овозможува подобра генерализација. Дополнително, оваа техника овозможува оптимално искористување на податоците, бидејќи секој податок се користи и за тренирање и за тестирање, што е особено значајно при работа со мали бази на податоци. Конечно, со тоа што моделот се оценува на различни делови од податоците, се обезбедува пореалистична и порелевантна метрика за неговата изведба.

Оптимизацијата на хиперпараметрите во моделите за машинско учење е од суштинско значење бидејќи изборот на соодветни хиперпараметри директно влијае

врз изведбата, точноста и способноста за генерализација на моделот [190]. Хиперпараметрите се параметри кои не се учат директно од податоците, туку се поставуваат пред процесот на тренирање и ја контролираат сложеноста и адаптивноста на моделот.

Постојат различни методи за оптимизација на хиперпараметрите, меѓу кои најчесто користени се Grid Search, Random Search и Бајесова оптимизација. Во овој труд се користи Бајесовата оптимизација, бидејќи таа претставува попрецизен и побрз метод во споредба со традиционалните техники, особено кога просторот на хиперпараметрите е голем и високо-димензионален [191].

Бајесовата оптимизација е веројатносен алгоритам за оптимизација, кој гради статистички модел на целната функција (на пример, точноста или функцијата на загуба за даден сет на хиперпараметри) и потоа ги бара најверојатните оптимални вредности [192]. Оваа техника ги користи претходни мерења за да ги идентификува најефикасните хиперпараметри за евалуација, што значи дека со секој чекор алгоритамот динамично ги оптимизира вредностите на хиперпараметрите прилагодувајќи се на претходните мерења. Во контекст на ова истражување, Бајесовата оптимизација е избрана заради нејзината ефикасност во решавање на сложени модели со голем број на влезни податоци, каде што тестирањето на хиперпараметрите бара пресметковна моќ и е временски интензивно.

6.3. Развој, имплементација и тестирање на модели со машинско учење за класификација на типот и состојбата на материјалот

Како што беше претходно објаснето, интензитетите од коригираниот емисионен спектар во видливиот и дел од блиску-црвениот опсег на бранови должини се искористени како влезни податоци за класификациските модели. Спектралните податоци, кои ги опфаќаат брановите должини од 400 до 900 nm, претставуваат карактеристичен отпечаток на материјалите и се клучни за идентификацијата на типот на материјал и состојбата на правот. Во овој опсег собрани се вкупно вкупно 884 влезови кои се коригираните интензитетите на спектрите на соодветните бранови должини. Како излезни податоци се четирите класи според дефиницијата на Слика 6.1.

Имплементирани се пет различни модели за класификација: збирни модели со метод на адаптивно засилување и со метод на агрегирање со повеќекратно избирање примероци, Бајесов наивен модел, k-најблиски соседи, и машини со носечки

вектори, со цел да се спореди нивната точност и способност за класификација. Моделите и нивната структура се детално објаснети во Поглавје 3.2. Овие модели беа тестирани затоа што нудат различни пристапи кон класификацијата и овозможуваат споредба на изведбата во зависност од комплексноста на моделот и карактеристиките на податоците. Осум проценти од собраните експериментални податоците беа користени како множество на податоци за тестирање, и не беа користени во фазите на тренирање и валидација на моделот. Подмножеството за тестирање се користи за да се процени генералната способност на моделот да се справи со непознати податоци.

Точноста на моделите е оценета преку конфузни матрици добиени од множества на податоци за валидација и за тестирање. Покрај точноста, дополнителни метрики кои се користени за подобра проценка на изведбата на моделите се стапката на вистински позитиви (True Positive Rate - TPR), вредностите на позитивни предвидувања (Positive Predictive Value - PPV), стапката на лажно негативни (False Negative Rate - FNR) и стапката на лажни откритија (False Discovery Rate - FDR), кои детално се објаснети во Поглавје 3.5.

6.3.1. Имплементација и резултати од збирниот модел со метод на засилување за класификација

Во ова истражување, прв применет метод за класификација е збиен модел со метод на адаптивно засилување. Овој пристап е познат по неговата способност да ги комбинира слабите ученици, како што се дрвјата на одлука, за да се создаде силен ученик. Деталното објаснување на овој модел е во Поглавје 3.2.1.

Со помош на Бајесовата оптимизација беа оптимизирани хиперпараметрите потребни во збирниот модел со адаптивно засилување: број на дрвја, максималниот број на поделби и бројот на избрани влезови во секој чекор. Дополнително, како хиперпараметар е и стапката на учење која го одредува придонесот на секое дрво во конечниот резултат и ја контролира брзината со која алгоритмот напредува низ методот за учење со намалување на градиентот. Вообичаено вредностите на овој хиперпараметар се движат во опсег од 0 до 1, при што типичните вредности се помеѓу 0.001 и 0.3. Помалите вредности го прават моделот поотпорен на специфичните карактеристики на секое индивидуално дрво, овозможувајќи на моделот да генерализира подобро на нови податоци. Дополнително, со помалите вредности може да се спречи прекумерното прилагодување на податоците, но го зголемуваат ризикот моделот да не го достигне оптимумот при фиксен број на дрвја и бараат поголема пресметковна моќ. Во ова истражување, вредноста на стапката на

учење не се оптимизираше туку се користеше стапка од 0.1, бидејќи е најчесто применета и обезбедува баланс помеѓу стабилноста и точноста на моделот.

Бројот на дрвја го претставува вкупниот број на индивидуални дрвја на одлука (слаби ученици) кои ќе бидат комбинирани во збирниот модел. Во адаптивното засилување, дрвјата се додаваат последователно, при што секое ново дрво се тренира за да ги коригира грешките направени од претходните дрвја и со тоа придонесува на предвидувачката точност на моделот. Овој процес овозможува моделот постепено да се подобрува, но бројот на дрвја мора внимателно да се избере. Премал број на дрвја може да резултира со недоволно трениран модел кој не ја постигнува посакуваната точност, додека премногу дрвја може да доведат до прекумерно прилагодување на податоците за тренирање. За овој модел беше избран оптимален број на дрвја од 30.

Максималниот број на поделби е хиперпараметар што ја одредува сложеноста на секое поединечно дрво во збирниот модел. Овој параметар ја дефинира максималната длабочина на дрвото и бројот на одлуки што едно дрво може да ги направи пред да заврши со својата структура. Поголемиот број на поделби овозможува дрвото да ги моделира посложените интеракции во податоците, што може да ја зголеми точноста на моделот. Сепак, премногу поделби може да доведат до прекумерно прилагодување на податоците, бидејќи дрвото ќе биде измоделирано премногу специфично за податоците за тренирање. Од друга страна, ако бројот на поделби е премал, дрвото може да биде премногу едноставно и да не ја долови сложеноста на податоците, што доведува до недоволно тренирање и мала точност. Во овој модел, максималниот број на поделби беше оптимизиран на вредност од 20.

Бројот на избрани влезови во секој чекор е хиперпараметар што го контролира бројот на влезови (предиктори) кои се земаат во предвид при растење на секое дрво во збирниот моделот. Вредноста на овој хиперпараметар е важен за одредувањето на разновидноста на моделот. Ако бројот на предиктори за избор е премногу мал, секое дрво ќе има ограничени информации, што може да ја намали точноста на моделот. Од друга страна, ако бројот на предиктори за избор е премногу голем, сите дрвја во моделот ќе бидат многу слични, што може да го ограничи придонесот на дрвото во намалувањето на грешките. Во моделот, бројот на предиктори за избор беше оптимизиран на 28. Оваа вредност одговара на квадратниот корен од вкупниот број на предиктори што е практично правило кое се следи за избор на вредноста во случаи кога не се прави оптимизација.

Со користење на овие оптимизирани хиперпараметри, резултатите од предвидувањето на моделот покажаа дека точноста на валидациското подмножество е 68.8%, додека точноста на подмножеството за тестирање е 66.7%. Овие резултати укажуваат на слаба изведба на моделот. Конфузните матрици за валидацијата и тестирањето се прикажани на Слика 6.5 со метриците за евалуација TPR, FNR, PPV

и FDR, од каде што е видно дека моделот покажува особено ниска точност во класификацијата на третата класа (Ti-6Al-4V - прав), која често е погрешно класифицирана како првата класа (AISI316L - прав).

Овие резултати укажуваат дека овој модел за машинско учење со избраните хиперпараметри не е оптимален за задачата и потребен е избор на алтернативен модел за класификација.

		Предвидена класа					
		1	2	3	4		
Вистинска класа	1	83		10	2	87.4%	12.6%
	2	14	51		4	73.9%	26.1%
	3	23		17	3	39.5%	60.5%
	4	12	4	6	21	48.8%	51.2%
						TPR	FNR
PPV		62.9%	92.7%	51.5%	70.0%		
FDR		37.1%	7.3%	48.5%	30.0%		

а)

		Предвидена класа					
		1	2	3	4		
Вистинска класа	1	6	1	2		66.7%	33.3%
	2		6			100.0%	
	3	2		1		33.3%	66.7%
	4			2	1	33.3%	66.7%
						TPR	FNR
PPV		62.9%	92.7%	51.5%	70.0%		
FDR		37.1%	7.3%	48.5%	30.0%		

б)

Слика 6.5: Конфузни матрици од примената на збирниот модел со метод на засилување за класификација: а) резултати од валидација, б) резултати од тестирање

6.3.2. Имплементација и резултати од збирниот модел со метод на агрегирање за класификација

Во овој дел од истражувањето беше применет збирен модел со метод на агрегирање со повеќекратно избирање примероци за класификација. Како што е детално изведено во Поглавјето 3.2.2, овој метод работи на принципот на генерирање повеќе подмножества од оригиналното множество на податоци, при што за секое подмножество се гради посебно дрво на одлучување независно едно од друго. Применета е техниката со замена, каде при креирањето на подгрупи од оригиналното множество на податоци, секој податок од множеството може да биде избран повеќе од еднаш. Предвидувањата од сите дрвја потоа се комбинираат за да се добие конечниот резултат од моделирањето.

За моделот беа оптимизирани неколку хиперпараметри кои се идентични на оние кај збирниот модел со метод на адаптивно засилување, односно бројот на дрвја, максималниот број на поделби и број на избрани дрвја во секој чекор.

Прво, бројот на избрани дрвја во секој чекор со Бајесовата оптимизација беше оптимизиран на 30, што повторно соодветствува на правилото дека бројот на предиктори треба да биде приближно еднаков на квадратниот корен од вкупниот број на влезови.

Максималниот број на поделби на дрвјата е оптимизиран на 75, што овозможува дрвјата да бидат доволно сложени за да ги фатат посложените интеракции во податоците, без притоа да го зголемат ризикот од преголемо прилагодување. Бројот на дрвја во моделот е оптимизиран на 26 за соодветно комбинирање на повеќе предвидувања за постигнување на подобра изведба.

Резултатите покажаа дека точноста на моделот за подмножество за валидација со примена на методот за вкрстена валидација со 5 сегменти е 78.2%, додека точноста на предвидување на податоците од подмножеството за тестирање е 81.1%. Оваа изведба е значително подобра во споредба со збирниот модел со метод на адаптивно засилување. На Слика 6.6 се прикажани конфузните матрици за валидацијата и тестирањето. Од нив може да се забележи дека најголемата грешка се случува при класификацијата на третата класа (Ti-6Al-4V - прав), која често е погрешно класифицирана како првата класа (AISI316L - прав). Овие резултати укажуваат дека збирниот модел со метод на агрегирање со повеќекратно избирање примероци обезбедува подобри предвидувања во однос на моделот со примена на методот на адаптивно засилување, но сепак со друг модел на машинско учење може да се добие понатамошно подобрување во точноста на класификацијата.

		Предвидена класа					
		1	2	3	4		
Вистинска класа	1	88		6	1	92.6%	7.4%
	2		66	1	2	95.7%	4.3%
	3	26		15	2	34.9%	65.1%
	4	3	3	11	26	60.5%	39.5%
						TPR	FNR
PPV		75.2%	95.7%	45.5%	83.9%		
FDR		24.8%	4.3%	54.5%	16.1%		

а)

		Предвидена класа					
		1	2	3	4		
Вистинска класа	1	9				100.0%	
	2		6			100.0%	
	3	2		1		33.3%	66.7%
	4			2	1	33.3%	66.7%
						TPR	FNR
PPV		81.8%	100.0%	33.3%	100.0%		
FDR		18.2%		66.7%			

б)

Слика 6.6: Конфузни матрици од примената на збирниот модел со метод на агрегирање за класификација: а) резултати од валидација, б) резултати од тестирање

6.3.3. Имплементација и резултати од машините со носечки вектори

Со цел моделирање на системот со класификација на податоците беше применет алгоритмот на машини со носечки вектори, чии што теоретски основи се дадени во

Поглавјето 3.2.5. При имплементацијата на Бајесовата оптимизација се оптимизираат три хиперпараметри на моделот: „кERNEL“ функцијата, регулациониот параметар C и коефициентот γ (гама).

Кернел функцијата го одредува начинот на мапирање на влезните податоци во повисокодимензионален простор, со цел да се најде оптималната хипер-рамнина која ги разделува различните класи, доколку тоа не е можно во оригиналниот простор на податоците. Математичките равенки на кернел функциите се прикажани во Поглавје 3.2.5. Во ова истражување беше избрана кернел функцијата со радијална основа (равенка дадена во Табела 3-1), бидејќи е погодна за работа со нелинеарно распределени податоци.

Хиперпараметрите C и γ ја дефинираат кернел функцијата и се оптимизираат преку методот на Бајесова оптимизација.

Вредноста на коефициентот γ ја контролира сложеноста на мапирањето во повисокодимензионалниот простор со контролирање на влијанието на секоја поединечна точка од податоците врз функцијата за одлука [193]. Всушност, γ ја одредува „ширината“ на кернел функцијата, односно колку блиску или далеку може една точка да има значајно влијание врз другите точки. Помалите вредности на γ резултираат со поширока функција, што значи дека повеќе точки од податоците имаат влијание врз функцијата за одлука. Ова може да резултира со порамномерна хипер-рамнина, но исто така и со модел кој е помалку точен за нови податоци. Од друга страна, поголемите вредности на γ водат до потесна функција, каде што влијанието на секоја точка е ограничено на поблизок соседен простор. Ова може да резултира со подобра способност за доловување на локалните карактеристики, но и со зголемен ризик од прекумерно прилагодување на податоците. Правилниот избор на вредност за γ е од суштинско значење за постигнување на баланс помеѓу точноста и генералната применливост на моделот. Процесот на оптимизација на γ се изврши во опсег од $[10^{-3}, 1000]$, при што најдобри резултати се покажаа при $\gamma = 20$.

Оптимизирањето на хиперпараметарот C се изврши во опсегот $[10^{-3}, 1000]$, при што најоптималната вредност е $C = 884$.

Со вака дефинирани хиперпараметри и трениран модел, резултатите покажаа дека точноста на моделот на валидациското подмножество со метод на вкрстена валидација со 5 сегменти е 88.8%, додека точноста на предвидување на податоците од подмножеството за тестирање достигна 95.2%. Конфузните матрици за двете подмножества се прикажани на Слика 6.7. Може да се забележи дека во фазата на тестирање има само една грешна класификација, каде што класата 4 (Ti-6Al-4V – без прав) е погрешно класифицирана како класа 3 (Ti-6Al-4V - прав).

		Предвидена класа					
		1	2	3	4		
Вистинска класа	1	91		4		95.8%	4.2%
	2		68		1	98.6%	1.4%
	3	4		30	9	69.8%	30.2%
	4	1		9	33	76.7%	23.3%
						TPR	FNR
PPV		94.8%	100.0%	69.8%	76.7%		
FDR		5.2%		30.2%	23.3%		

a)

		Предвидена класа					
		1	2	3	4		
Вистинска класа	1	9				100.0%	
	2		6			100.0%	
	3			3		100.0%	
	4			1	2	66.7%	33.3%
						TPR	FNR
PPV		100.0%	100.0%	75.0%	100.0%		
FDR				25.0%			

б)

Слика 6.7: Конфузни матрици од примената на машини со носечки вектори: а) резултати од валидација, б) резултати од тестирање


6.3.4. Имплементација и резултати од алгоритмот k -најблиски соседи

Следен алгоритмот со машинско учење кој беше развиен и применет за класификација е алгоритмот на k -најблиски соседи. Во овој алгоритам е потребно да се оптимизира хиперпараметарот k , кој го претставува бројот на најблиски соседи кои се користат за да се одреди класата на даден примерок. Алгоритмот ги бара k - те најблиски соседи на точката што се класифицира и потоа ја одредува класата врз основа на мнозинската класа на овие соседи. Објаснувањето за начинот на функционирање на овој модел се наоѓа во Поглавје 3.2.4.


Оптимален избор на хиперпараметарот k е важен бидејќи доколку избраната вредност е мала, тогаш моделот станува чувствителен на шум во податоците, бидејќи класификацијата зависи од мал број на соседи кои може да се случи да се шумови. Додека доколку избраната вредност е голема, тогаш моделот разгледува голем број на соседи, вклучувајќи ги и оние што може да бидат далеку од целната точка, што може да доведе до недоволно прилагодување на податоците и помалку точни предвидувања. Со оптимален избор на k треба од една страна да се намали влијанието на шумовите, а од друга да се долови локалната структура на податоците [194]. Со оптимизирањето на параметарот k беше утврдено дека најдобри резултати се постигнуваат со $k = 14$.

Дополнително, за моделот на k -најблиски соседи треба да се изберат метриката со која ќе се определи растојанието и тежината на растојанието. Метриката за растојание го одредува начинот на кој се пресметува растојанието помеѓу податоците во просторот. Во овој случај, беше избрана Евклидовата метрика за растојание, која е најчесто користена и се базира на геометриското растојание помеѓу две точки во повеќедимензионален простор. За тежината на растојанието, беше избрана „еднаква тежина“, што значи дека сите соседи имаат еднаков придонес при одредувањето на класата, без оглед на нивната близина.

Со вака дефиниран модел се доби точност на валидациското подмножество од 93.6%, додека точност на подмножеството на тестирање од 95.2%, што претставува модел кој со голема точност го моделира и предвидува процесот. Конфузните матрици за двете подмножества се прикажани на Слика 6.8, каде што се забележува дека направен е мал број на грешки при класификацијата. Кај валидациското подмножество, грешките вклучуваат класификација на класа 1 како класа 3 и на класа 4 како класа 3. Кај тестирачкото подмножество забележана е само една грешка, при што класа 4 е погрешно класифицирана како класа 1.



а)



б)

Слика 6.8: Конфузни матрици од примената на алгоритмот на k -најблиски соседи: а) резултати од валидација, б) резултати од тестирање

6.3.5. Имплементација и резултати од Бајесовиот наивен алгоритам

Како последен модел за класификација беше развиен и имплементиран Бајесовиот наивен алгоритам за класификација со машинско учење. Овој модел се базира на претпоставката дека сите фактори (предиктори) се независни еден од друг, што ја олеснува неговата имплементација и анализа но исто така го прави “наивен” и


подложен на одредени ограничувања кога влезовите се корелирани. Детално објаснување и математичка изведба на алгоритмот се дадени во Секција 2.2.3.

Бидејќи влезовите во моделот се континуирани вредности, користен е алгоритмот Гаусов наивен Бајес, каде излезната променлива се пресметува според равенката (3-24).


Кај овој алгоритам може да се оптимизира хиперпараметарот наречен коефициент за мазнење на варијансата, со кој се додава мал износ на варијансата на влезните податоци со цел да се реши проблемот на нулта веројатност која може да се појави при пресметките на веројатностите. Сепак, овој параметар е произволен и во моделот развиен во ова истражување не се користи.

После тренирањето на моделот, точноста при валидацијата се покажа дека е 54.4%, додека при тестирањето е 61.9%. Оваа изведба е значително послаба во споредба со другите модели што се користени. На Слика 6.9 се прикажани конфузните матрици за подмножествата за валидација и тестирање. Од конфузните матрици е јасно дека има значителни грешки во класификацијата на сите класи. Кај валидациското подмножество, особено големи грешки се забележани при класификацијата на класа 1, каде што голем дел од податоците се класифицирани во класа 3. Дополнително, значајни грешки се направени и при класификацијата на класа 2, која често се предвидува како класа 4, класа 3 која се предвидува како класа 1, и класа 4 која неправилно се предвидува како класа 2 или класа 3 за голем број податоци.

Во фазата на тестирање исто така се забележуваат голем број на погрешно класифицирани податоци, со слични грешки како кај валидациската фаза. Овие резултати покажуваат дека Бајесовиот наивен модел не е соодветен за оваа класификациска задача, веројатно поради претпоставката за независност помеѓу карактеристиките и ограничувањата на Гаусовата распределбата за моделирање на податоците.



а)



б)

Слика 6.9: Конфузни матрици од примената на Бајесовиот наивен алгоритам: а) резултати од валидација, б) резултати од тестирање

6.3.6. Споредбени анализи за точноста и брзината на предвидување на моделите со машинско учење за класификација

На Слика 6.10 се прикажани резултатите од споредбата на точноста на сите тестирани модели за класификација, при што се разликуваат резултатите од фазата


на валидација (сини столбчиња) и резултатите од фазата на тестирање (црвени столбчиња).

Од графикот се забележува дека моделот со најголема точност на предвидување е k -најблиски соседи, додека алгоритмот Гаусов наивен Бајес резултира со најмала точност. Овој резултат може да се објасни со теоретските основи на моделите и нивната адаптација кон податоците. Алгоритмот на k -најблиски соседи, кој се заснова на мерка на сличност, е поуспешен во класификација на спектралните податоци, бидејќи класифицира податоци со слични емисиони карактеристики. Од друга страна, алгоритмот Гаусов наивен Бајес претпоставува независност на карактеристиките и нормална распределба на податоците, што не секогаш е соодветно за комплексни спектрални податоци. Може да се заклучи дека методи кои земаат предвид локални односи и сличности меѓу податоците можат да обезбедат подобра точност во предвидувањата во ова истражување.

Резултатите ја истакнуваат ефективноста на моделот k -најблиски соседи за предвидување на типот и состојбата на материјалот, врз основа на спектралните информации добиени од процесот на мониторинг. Моделот покажа висока предвидувачка способност за разликување дали ласерот топи прав или работи во отсуство на прав, со што ефикасно предвидува дефекти на денудација, како и идентификување на типот на материјалот.


Дополнително, за да се оцени перформансот на моделите, анализирана е и брзината на предвидување, која претставува број на предвидувања во секунда. Оваа метрика е од особена важност доколку моделот треба да биде интегриран во систем за контрола на процесот во реално време, каде што е неопходно да се анализираат што е можно повеќе податоци во најкраток временски интервал.

На Слика 6.11 е прикажана брзината на предвидување на имплементираниите модели за класификација. Се забележува дека збирните модели и моделот со носечки вектори имаат највисока брзина на предвидување од над 300 примероци во секунда. Од друга страна, алгоритмот k -најблиски соседи има значително помала брзина на предвидување во споредба со претходните модели, што е очекувано поради неговиот принцип на работа да при секое предвидување мора да се пресмета растојанието до сите податоци во множеството за тренирање, што значително го зголемува времето. Најбавен модел во споредбата е Бајесовиот наивен алгоритмот, што може да се должи на специфичниот начин на пресметка на веројатностите за секоја класа, што во овој случај не се покажува како оптимално во однос на брзината.



Модели со машинско учење за класификација

Слика 6.10: Споредба на добиената точност на моделите со машинско учење за класификација во фазите на валидација и тестирање



Модели со машинско учење за класификација

Слика 6.11: Споредба на брзината на предвидување на моделите со машинско учење за класификација

Со ова може да се заклучи дека доколку приоритетно барање е високата брзина на предвидување тогаш потребно е да се направи компромис помеѓу точноста и пресметковната брзина на моделот. Во тој контекст, алгоритмот кој се базира на машина со носечки вектори се покажува како најсоодветна опција. Иако точноста на овој модел е малку пониска од моделот k -најблиски соседи (околу 5% пониска во фазата на валидација, а идентична точност во фазата на тестирање), сепак обезбедува значително побрза предвидувачка способност, со што овозможува поефикасна анализа на податоците и донесување на одлука во реално време.

6.4. Развој, имплементација и тестирање на модели со машинско учење за регресија за предвидување на дијаметарот на стопениот регион

Во овој дел од истражувањето се развиваат и анализираат модели за регресија со цел да се направи предиктивен модел кој ќе го процени дијаметарот на стопениот регион d_{melt} во зависност од спектралната емисија и претходно утврдената класа на материјалот. Како што веќе беше објаснето во рамковниот модел, излезот од класификациониот модел влегува како влез во регресиониот модел, бидејќи тестирањата покажаа дека оваа комбинација резултира со повисока точност во предвидувањата отколку ако се користи само спектралната емисија како влезен параметар.

Евалуацијата на точноста на различните регресиони модели е извршена користејќи ја метриката R^2 , која ги мери пропорциите на варијацијата на зависната променлива што е објаснета преку независните променливи во моделот. Дополнително, се прикажува и метриката корен од средната квадратна грешка (RMSE), која обезбедува увид во просечната грешка на моделот.

Тестирани се пет регресиони модели со машинско учење, вклучувајќи ги моделот на регресија со Гаусов процес, методи на збирни модели, регресија со носечки вектори, и вештачки невронски мрежи (ВНМ). Направена е компаративна анализа на нивната изведба и се бира моделот кој најточно ги предвидува резултатите.

И во овој дел, за валидирање на моделите е користен методот на вкрстена валидација со 5 сегменти. Дополнително, 10% од податоците беа издвоени како подмножество за тестирање за да се провери точноста на моделите на сосема нови податоци и да се провери способноста за генерализација на моделот. За оптимизација на хиперпараметрите кај сите модели е користена Бајесова оптимизација.

Како илустративен пример за основен регресионен модел беше применет и оценет линеарен регресионен модел. Овој модел покажа негативна R^2 вредност, што укажува дека линеарниот модел обезбедува послабо моделирање на податоците во споредба со едноставна хоризонтална линија, која претставува основен модел што ја рефлектира нултата хипотеза.

6.4.1. Имплементација и резултати од моделот на регресија со Гаусов процес

Како прв модел за решавање на регресиониот проблем во ова истражување беше применет алгоритам за регресија со Гаусов процес кој претставува непараметарски веројатносен модел. Овој алгоритам го моделира односот помеѓу факторите и излезните променливи користејќи Гаусови процеси како основа, односно секое предвидување се третира како Гаусова распределба со средна вредност (μ) и варијанса (σ^2). Моделот за регресија со Гаусов процес се базира на кернел функција, која ја дефинира коваријантната матрица што ја опишува корелацијата во одзивот како функција од растојанието помеѓу вредностите на влезните податоци. Објаснувањето и математичката презентација на овој модел како и кернел функциите е дадено во Поглавје 3.3.1.

За овој модел, беше избрана кернел функција со радијална основа чија равенка е дадена во Табела 3-2. Хиперпараметрите на кернелот кои е потребно да се оптимизираат со Бајесова оптимизација се должината (l) и стандардната девијација (σ) на кернел функцијата. Хиперпараметарот за должина на кернел функцијата ја контролира должината на влијанието на функцијата и одредува колку брзо се намалува корелацијата помеѓу две точки во зависност од нивното растојание во простор на факторите. Помала вредност на должината на кернел функцијата може да резултира со модел кој е чувствителен на локалните варијации во податоците, со што може подобро да ги опфати варијациите, но истовремено и да доведе до прекумерно прилагодување на податоците. Од друга страна, поголема вредност на должината резултира со поширок обем на влијание, што го прави моделот помазен и со помала тенденција за прекумерно прилагодување, но со ризик да ги пропушти локалните варијации. Како оптимална вредност на овој хиперпараметар беше пресметано и дефинирано 4.81.

Хиперпараметарот кој ја одредува стандардната девијација на кернел функцијата ја одредува големината на варијациите односно степенот на ширењето на функцијата, што влијае на тоа како моделот ја пресметува неизвесноста во предвидувањата. Како оптимална вредност на овој хиперпараметар беше пресметано и дефинирано 54.98.

Со тренирањето на моделот со вака оптимирани хиперпараметри, се постигна следната точност изразена преку R^2 коефициент:


- 0.92 за валидациското подмножество,
- 0.95 за податоците во подмножеството за тренирање.

Исто така, се постигнаа следните вредности на коренот на средната квадратна грешка (RMSE):

- 19.32 за валидациското подмножество,
- 13.84 за податоците во подмножеството за тренирање.

На Слика 6.12 а) е прикажан дијаграм на расејување на вистинските наспроти предвидените вредности на d_{melt} добиени со развиениот модел, на кој податоците за валидација и тестирање се претставени со различни бои за ефикасно разграничување. Овој дијаграм овозможува визуелна проценка на точноста на предвидувањата на моделот. Од графикот може да се забележи дека податоците се концентрирани околу референтната линија на идеалното предвидување, што укажува дека моделот дава резултати блиски до вистинските вредности. Колку поблиску податоците се наоѓаат до оваа линија, толку помала е грешката на предвидување односно разликата помеѓу предвидените и вистинските вредности е помала, што го потврдува високиот степен на точност на моделот.

На Слика 6.12 б) е прикажан хистограм на остатоците, кој ја илустрира дистрибуцијата на грешките на предвидување за двете подмножества на податоци (за валидација и тестирање). Остатоците претставуваат разлика помеѓу вистински измерениот дијаметар на стопената зона и предвидените вредности од моделот, што ги претставува грешките во предвидувањето. Хистограмот покажува дека овие грешки следат приближно нормална дистрибуција, концентрирајќи се симетрично околу нултата вредност. Отсуството на јасно изразени исклучоци во податоците или значајни отстапувања во распределбата на остатоците укажува на тоа дека избраниот модел дава стабилни предвидувања.



Слика 6.12: Резултати од примената на моделот на регресија со Гаусов процес за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на d_{melt} ; б) хистограм на остатоците

6.4.2. Имплементација и резултати од регресијата со носечки вектори

Во оваа секција се прикажани имплементацијата и резултатите од моделот за регресија со носечки вектори, кој се заснова на пресметување на оптимална хиперрамнина што ја минимизира грешката помеѓу предвидените и реалните вредности (Поглавје 3.3.2). За мапирање на влезните податоци во повисока димензија, со цел да се пронајде линеарна поврзаност во простори каде што оригиналните податоци не се линеарно разделиви се користеше кернел функцијата со радијална основа.

Хиперпараметрите кои се оптимизираа во процесот на Бајесова оптимизација се истите како и кај моделот со носечки вектори за класификација: регулациониот коефициент C и коефициентот γ , но дополнително кај регресијата со носечки вектори потребен е и коефициентот ϵ . Овој хиперпараметар дефинира толеранција за грешка, при што грешките помали од оваа вредност не се казнуваат. Вредноста на ϵ дефинира област околу предвидените вредности, каде што секоја точка што лежи внатре во оваа област се смета за добро предвидена. Ова му овозможува на моделот да биде пофлексибилан и да не се обидува прекумерно да го приспособи секој индивидуален влезен примерок. При избор на соодветна вредност мора да се внимава на големи вредности на ϵ кои можат да резултираат со недоволно

прилагодување на податоците. Со примена на оптимизација, оптималната вредност на хиперпараметарот ε е 6.71.

Регулациониот параметар C е оптимизиран на вредност од 67.09, додека коефициентот γ на 10.

Точноста на моделот, мерена преку метриката R^2 , е:


- 0.90 во фаза на валидација,
- 0.94 во фаза на тестирање.

Додека, коренот на средната квадратна грешка (RMSE) има вредност:

- 21.46 за валидациското подмножество,
- 15.39 за подмножеството за тестирање.

Дијаграмот на расејување на вистинските наспроти предвидените вредности на d_{melt} добиени со моделот за регресија со Гаусов процес е прикажан на Слика 6.13 а), каде се забележува дека податоците се распоредени блиску до линијата на идеално предвидување, што укажува на добра согласност помеѓу предвидените и вистинските вредности. Сепак, може да се забележи отстапување кај дијаметрите со многу мала и многу голема вредност, каде што моделот не ги предвидува со висока точност, додека во средниот опсег предвидувањата се значително попрецизни.

На Слика 6.13 б) е прикажан хистограм на остатоците, каде се гледа дека остатоците од валидацијата ја следат нормалната распределба и се приближно симетрично распределени околу нултата вредност, без изразени аномалии. Остатоците од тестирањето, иако немаат нормална распределба, сепак се концентрирани околу нултата вредност. Најголемите грешки, кои достигнуваат речиси $-40 \mu m$, се појавуваат кај најмалите дијаметри на стопен регион, при што моделот има тенденција да ги преценува и предвидува како значително поголеми.



Слика 6.13: Резултати од примената на моделот на регресија со носечки вектори за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на d_{melt} ; б) хистограм на остатоците

6.4.3. Имплементација и резултати од збирниот модел со метод на засилување за регресија

Збирниот модел базиран на засилување е применет и за моделирање со регресија, математички изведен во Поглавјето 3.3.3. За таа цел се користи моделот на засилување со метод на најмалку квадрати. При секоја итерација, секое ново дрво на одлучување е дизајнирано да ја поправи квадратната грешка помеѓу предвидените и вистинските вредности на претходно предвидените вредности.

За стапка на учење беше избрана вредноста 0.1, која е препорачана почетна вредност за методите со засилување и ја одредува брзината со која моделот учи од грешките. Со ниска вредност како 0.1 се овозможува моделот да биде попрецизен и поотпорен на прекумерно прилагодување, но бара поголем број итерации за да се постигне оптималното решение.

Со примена на Бајесовата оптимизација се оптимизираа следните хиперпараметри на моделот: број на дрвја, минимална големина на листот, и бројот на избрани влезови во секој чекор. Оптималната вредност на бројот на дрвја е 113, а оптималната вредност на бројот на избрани влезови во секој чекор е 26, што приближно соодветствува на квадратниот корен од вкупниот број на фактори.

Хиперпараметарот за минимална големина на листот го одредува минималниот број на податоци што се потребни за формирање на листот (види Слика 3.4), што претставува крајниот јазол во дрвото каде што се вршат предвидувањата и каде што податоците се групираат врз основа на слични карактеристики. Овој параметар го контролира нивото на деталност и сложеност на дрвото, со што треба да се избере оптимална вредност за да се избегне прекумерно прилагодување од една страна, и намалена точност на предвидување од друга страна. При процесот на оптимизација се дефинирање вредноста на минималната големина на листот да е 17 податоци.


По оптимизацијата на хиперпараметрите, моделот ги постигна следните резултати за R^2 :

- 0.89 на валидациското подмножество,
- 0.93 на податоците за тестирање,

и следните вредности на коренот на средната квадратна грешка (RMSE):

- 22.57 за валидациското подмножество,
- 16.01 за податоците за тестирање.

На Слика 6.14 е прикажан дијаграмот на расејување и хистограмот на остатоците за предвидувањето со збирниот модел со засилување за регресија. Дијаграмот на расејување покажува дека податоците генерално ја следат линијата на идеалното предвидување, со некои поголеми отстапувања. Хистограмот на остатоците укажува дека грешките се концентрирани околу нултата вредност, што е позитивен индикатор за стабилноста на моделот, а дистрибуцијата на податоците генерално следи нормална распределба. Кај податоците за валидација и тестирање, се забележуваат повеќе грешки со негативен предзнак, што укажува дека моделот има тенденција да ги преценува дијаметрите и да предвидува зголемена вредност на d_{melt} . Тоа особено се забележува кај хистограмот на остатоците од фазата на тестирање каде податоците се натрупани од страната на дијаграмот со негативни остатоци.



Слика 6.14: Резултати од примената на збирен модел со метод на засилување за регресија за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на d_{melt} ; б) хистограм на остатоците

6.4.4. Имплементација и резултати од збирниот модел со метод на агрегирање за регресија

Алгоритмот за збирен модел базиран на агрегирање со повеќекратно избирање примероци освен за класификациони проблеми може да се примени и за регресиони, на начин теоретски објаснет во Поглавје 3.3.4.

За да се подобри точноста на моделот, беа оптимизирани следните хиперпараметри: бројот на избрани влезови во секој чекор е 30, бројот на дрвја на одлучување е 30, и вредноста на минималната големина на листот е 8.


Со тренирање на моделот со овие оптимизирани хиперпараметри се добија следните вредности на метриката за евалуација R^2 :

- 0.89 на валидацискиот сет,
- 0.93 на тестирачкиот сет;

и следните вредности на метриката за евалуација корен на средната квадратна грешка (RMSE):

- 22.67 за валидацискиот сет,
- 16.30 за тестирачкиот сет.

Прикажани се дијаграмот на расејување и хистограмот на остатоците. Дијаграмот на расејување покажува генерално задоволителни резултати, со податоци кои се групирани околу линијата на идеалното предвидување. Хистограмот овозможува подобра анализа на грешките што ги прави моделот. За валидациското подмножество, грешките генерално следат нормална распределба околу нулата, што укажува на стабилност на предвидувањата. Кај подмножеството за тестирање, се забележува највисок столб односно столб со најголем број на податоци лево од нулата, со негативен предзнак, а не на нултата вредност. Дополнително, се забележува и едно изразено отстапување во негативната област. Се забележува дека, споредбено со бројот на остатоци со негативен предзнак, има приближно еднаков број на остаоци со позитивен предзнак каде моделот предвидува помал d_{melt} од оној вистинскиот, но тие се порамномерно распределени.




Слика 6.15: Резултати од примената на збиен модел со метод на агрегирање за регресија за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на d_{melt} ; б) хистограм на остатоците

6.4.5. Имплементација и резултати од вештачките невронски мрежи

Како последен модел со машинско учење за регресија е презентирана имплементацијата и резултатите од моделот на вештачки невронски мрежи (ВНМ)

за регресија. Во Поглавјето 3.3.5 е дадено детално објаснување за структурата на моделот. Применетиот метод за тренирање на тежините и компензациите во мрежата (види Слика 3.16) е алгоритмот limited-memory Broyden-Fletcher-Goldfarb-Shanno (LBFGS), кој се користи за минимизација на функцијата на загуба врз основа на средната квадратна грешка [195].

При развојот на ВНМ моделот, беа дефинирани и оптимизирани следниве хиперпараметри: број на скриени слоеви, број на неврони во скриен слој, активациона функција, стапка на учење, големина на пакет, број на епохи и јачина на регуларизација. За да се оптимизира број на скриени слоеви се тестираа 1, 2 и 3 скриени слоеви, за да се избегне сложеноста на длабока невронска мрежа. Избрани се 2 слоеви како оптимален број. Вредноста на бројот на неврони по слој беше тестирана во опсег помеѓу [1, 300], при што како најдобар број беше избран 10 неврони за секој скриен слој. Структурата на вака дефинираната ВНМ е шематски претставена на Слика 6.16. Беа тестирани повеќе активациони функции: ReLU, Tanh, и Sigmoid (Табела 3-4), при што најдобар резултат покажа ReLU функцијата која овозможи поточно но и побрзо учење. Стапката на учење не се оптимизираше, туку се зема стандардната вредност од 0.001, што е вообичаен почетен избор за ВНМ модели.



Слика 6.16: Структура на имплементираната вештачка невронска мрежа со оптимизиран број на скриени слоеви и број на неврони во скриен слој

Големината на пакетите го одредува бројот на примероци од податоците за тренирање што се користат за ажурирање на тежините и компензациите на мрежата во секоја итерација. Како оптимална вредност е избрана големина од 32 примероци, која е често користена вредност бидејќи овозможува ефикасно користење на меморијата на GPU/CPU, а со тоа и баланс помеѓу брзината и точноста на тренирањето на моделот. Бројот на епохи ја дефинира бројката на целосни поминувања на невронската мрежа низ сите податоци за тренирање. Во секоја епоха, сите податоци од множеството за тренирање се обработуваат, а тежините и компензациите на мрежата се ажурираат според пресметаните градиенти. При процесот на оптимизација како најдобар број на епохи се покажа 100, што е доволно за мрежата да научи значајни трендови од податоците, а да се избегне потенцијално прекумерно прилагодување.

Јачината на регуларизација λ се користи за да се контролира процесот на тренирање на вештачките невронски мрежи преку намалување на ризикот од прекумерно прилагодување на податоците. Овој параметар додава казна во функцијата на загуба за големите вредности на тежините во мрежата, спречувајќи моделот да стане премногу сложен и да се прилагоди на шумот од податоците за тренирање наместо на значајните трендови. Во процесот на оптимизација, оптималната вредност на λ се бараше во опсегот од $[10^{-5}/n, 10^5/n]$ каде што n е вкупниот број на податоци. Оптимизираната вредност на овој хиперпараметар изнесува 7.87.

Со тренирање на модел на вештачка невронска мрежа со вака дефинирани хиперпараметри, моделот ги постигна следниве резултати за коефициентот на точност R^2 :

- 0.86 при валидацијата,
- 0.87 при тестирањето,


додека коренот на средната квадратна грешка (RMSE) изнесува:

- 25.84 за валидациското подмножество,
- 22.19 за подмножеството за тестирање.

На Слика 6.17 е прикажан дијаграмот на расејување за резултатите добиени со моделот на вештачки невронски мрежи. Видливо е дека податоците имаат тенденција да се групираат околу референтната линија на идеалното предвидување, но сепак постојат значителни отстапувања. Особено кај поголемите и помалите вредности на d_{melt} се забележува зголемена дисперзија, додека во средниот опсег резултатите се попрецизни, иако сè уште се присутни одредени поголеми отстапувања од вистинските вредности.

Кај хистограмот на остатоците за валидацијата може да се забележи нормална распределба околу нултата вредност, што е позитивен индикатор за стабилноста на


моделот. Кај подмножеството за тестирање се забележуваат поголеми грешки, вклучувајќи и отстапувања над $-50 \mu m$, што укажува на случаи каде моделот дава значително неточни предвидувања.



Слика 6.17: Резултати од примената на вештачка невронска мрежа за фазите на валидација и тестирање: а) дијаграм на расејување на вистинските наспроти предвидените вредности на d_{melt} ; б) хистограм на остатоците

6.4.6. Споредбени анализи за точноста и брзината на предвидување на моделите со машинско учење за регресија

На Слика 6.18 се прикажани и споредени R^2 вредностите за применетите модели на машинско учење за регресија, при што со сина боја е означено за подмножеството за валидација а со црвена за тестирање. Од сликата се забележува дека моделот за регресија со Гаусов процес постигнува највисока точност и во фазата на валидација и во фазата на тестирање на моделот. Останатите модели покажуваат нешто пониска точност споредбено со моделот за регресија со Гаусов процес, но разликата помеѓу моделите не е значителна, што укажува дека и другите модели со голема точност го предвидуваат излезот.




Слика 6.18: Споредба на добиената точност на моделите со машинско учење за регресија во фазите на валидација и тестирање

Фактот дека моделот за регресија со Гаусов процес дава најпрецизни предвидувања не е изненадувачки кога ќе се земе во обзир дека моделот е погоден за моделирање на комплексни, нелинеарни релации во множества на податоци со шумови и обезбедува предвидувања со јасно дефинирана неизвесност [196].

Нелинеарноста на податочното множество беше испитана со применување на линеарен модел за моделирање на зависностите во податоците, кој покажа многу ниска точност, што укажува на отсуство на линеарни корелации во податоците. Дополнително, очекувано е влезното множество на податоци да содржи шум поради различни извори на интерференција во сигналот на спектрометарот. Такви извори на шум може да произлезат од интеракции со околината на системот, меѓу кои надворешни фактори како варијации на температурата и вибрации [197].

Покрај тоа, детекторите во спектрометрите можат да покажат одредено ниво на "dark current" шум, кој претставува струја која се генерира дури и во отсуство на светлина, што може дополнително да придонесе за засилување на шумот во сигналот, особено во услови на слаба осветленост [197]. Овие фактори ја нагласуваат важноста на изборот на модел што може ефикасно да се справи со шумот во податоците, а моделот за регресија со Гаусов процес се покажува како најсоодветен метод во овој контекст.

Споредбата на брзината на предвидување на различните модели е прикажана на Слика 6.19, каде може да се види дека моделот за регресија со Гаусов процес има најголема брзина на предвидување. Со тоа, овој модел има највисока точност и воедно има и највисока брзина на предвидување, што го прави најефикасен без потреба од компромиси помеѓу точноста и брзината, особено значајно кога има потреба од предвидувања и контрола на процесот во реално време.




Слика 6.19: Споредба на брзината на предвидување на моделите со машинско учење за регресија

6.5. Имплементација и резултати од анализата на главни компоненти

За анализирање на емисионите спектри од металните легури, беше применета и анализа на главни компоненти (PCA) како алгоритам на ненадгледувано машинско учење. Целта на оваа анализа беше да се испита потенцијалот за разликување и идентификација на материјалите и нивната состојба (прашката состојба и полн материјал) врз основа на спектралните емисии добиени од зоната на интеракција помеѓу ласерот и материјалот.

Аналитички модел за истите цели веќе беше направен со алгоритми на надгледувано машинско учење за класификација (Поглавје 6.2), но во ова поглавје е анализирана и способноста на PCA заради предноста која ја овозможува за намалување на димензионалноста, што овозможува задржување на најзначајните информации од податоците, истовремено намалувајќи го бројот на влезни променливи. Математичката основа позади оваа анализа е изведена во Поглавје 3.4.

Дијаграмот на објаснета варијанса, прикажан на Слика 6.20, ја илустрира пропорцијата на објаснета варијанса од првите пет главни компоненти (равенка (3-71)). Овој дијаграм го прикажува графички односот помеѓу објаснетата варијанса на главните компоненти, односно мерката на придонесот на секоја компонента кон вкупната варијанса, и нивниот реден број. Дополнително, вредноста на објаснетата варијанса на секоја главна компонента е дадена во Табела 6-1.



Слика 6.20: Дијаграм на објаснета варијанса на првите пет главни компоненти, каде се забележува „израмнување“ на кривата по втората компонента

Првата главна компонента објаснува 93.43% од вкупната варијанса, што укажува на нејзиниот доминантен придонес во анализата. Втората компонента објаснува дополнителни 3.95%, додека третата придонесува со 1.05%. Придонесот на четвртата и сите последователни компоненти е под 1%, што значи дека нивното влијание врз вкупната варијанса е занемарливо. Со оглед на тоа што првите две главни компоненти заедно објаснуваат над 97% од варијансата во влезното податочко множество, тие се доволни за понатамошна анализа бидејќи ги сумираат критичните спектрални информации од податоците, додека останатите компоненти може да се отстранат од анализата.


Табела 6-1: Вредности на објаснета варијанса на првите пет главни компоненти добиени од анализата на главни компоненти

Главна компонента	Објаснета варијанса [%]
1	93.43
2	3.95
3	1.05
4	0.03
5	0.02

Оваа тенденција е исто така очигледна од дијаграмот на објаснета варијанса, каде што се забележува „израмнување“ на кривата на објаснета варијанса по втората компонента. Овој феномен покажува дека останатите компоненти придонесуваат со многу ниска вредност на дополнителна објаснета варијанса и затоа не треба да бидат земени предвид за понатамошна анализа. Исклучувањето на ваквите компоненти помага да се намали димензионалноста на податочното множество, задржувајќи ги само најзначајните информации и поедноставувајќи ја интерпретацијата на податоците.

Слика 6.21 прикажува график на проектираните координати, или „поените“, на значајните главни компоненти, со кој се визуелизираат позициите на влезните податоците во дводимензионален простор дефиниран од првата и втората главна компонента. Овој график ги прикажува проекциите на податоците врз основа на вредностите на главните компоненти според равенка (3-72), овозможувајќи анализа на нивниот распоред и идентификација на групирања или трендови.

Од прикажаниот график се забележува јасно разграничување помеѓу четири кластери на податоци, кои ги претставуваат четирите претходно дефинирани класи, односно двата различни материјали во двете состојби. Оваа поделба укажува на тоа дека материјалите се значително различни во однос на нивните спектрални карактеристики, што е одраз на нивниот состав и физичко-хемиските својства.



Слика 6.21: График на проектирани координати во дводимензионален простор дефиниран од првите два главни компоненти, препознавајќи ги четирите дефинирани класи

Од графикот може да се забележи дека кога втората главна компонента има многу мал придонес односно има вредност блиска до 0, а првата главна компонента има висок негативен придонес, четирите кластери почнуваат да се преклопуваат. Ова преклопување ја зголемува стапката на грешки при разликувањето и идентификувањето на материјалите, бидејќи кластерите не се јасно раздвоени во овој регион. Со понатамошна анализа се покажа дека овие податоци се собрани кога енергетскиот влез е многу низок, конкретно под 0.05 J, односно кога комбинацијата на моќноста на ласерот и времето на изложеност на ласерот резултира со енергетски влез под 0.05 J.

Во такви случаи, интензитетот на сигналот е низок бидејќи ласерот доставува минимална енергија до материјалот, што резултира со минимален интензитет на пламата што сензорот може да го регистрира. Ова намалено ниво на сигнал ја отежнува диференцијацијата помеѓу двата материјали при тие услови.

Подобрувањето на чувствителноста на сензорот преку модификации на оптичкиот ланец на мониторинг системот или имплементацијата на техники за засилување на сигналот може значително да ја зголеми сигурноста и точноста на идентификацијата на материјалите, особено во случаи на ниски енергетски влезови од ласерот. Ова би овозможило поефикасно и порелевантно следење на процесот, дури и во екстремни услови.

6.6. Заклучоци за поглавјето

Ова поглавје се фокусира на примената на алгоритми на машинско учење за анализа на спектралните податоци добиени од коаксијалниот OES мониторинг систем во LPBF процесот. Развиени се модели за класификација, регресија и анализа на главни компоненти (PCA) со цел автоматска идентификација на материјал, детекција на дефекти и проценка на параметри поврзани со процесот.

- Развиени се два посебни пристапи:
 - Надгледувано учење: за класификација (идентификација на материјалот и детекција на дефект на денудација) и регресија (предвидување на дијаметар на топен регион).
 - Ненадгледувано учење со PCA: за визуелизација, намалување на димензионалност и идентификација на кластери во податоците.
- За класификација се тестирани пет модели за класификација: збирни модели со метод на адаптивно засилување и со метод на агрегирање со повеќекратно избирање примероци, Бајесов наивен модел, k -најблиски соседи, и машини со носечки вектори.
 - Алгоритмот k -најблиски соседи резултираше со највисока точност за предвидување на состојбата на материјалот и откривање на денудација, бидејќи се базира на мерка на сличност и класифицира податоци со слични емисиони карактеристики.
 - Гаусовиот наивен Бајес покажа најслаба точност поради претпоставката за независност на карактеристиките и нормална распределба на податоците, што не соодветствува со комплексноста на спектралните податоци.
 - Анализата на брзината на предвидување покажа дека алгоритмот кој се базира на машина со носечки вектори има највисока брзина (над 300 предвидувања/секунда), што го прави најсоодветен за контрола во реално време, со мал компромис во точноста ($\sim 5\%$ помала точност од k -најблиски соседи во фазата на валидација, и идентична точност при тестирање).
- За регресија беа применети пет модели со машинско учење: моделот на регресија со Гаусов процес, збирни модели со два методи, регресија со носечки вектори, и вештачки невронски мрежи.
 - Моделот на регресија со Гаусов процес покажа највисока точност и стабилност во предвидување и во фаза на валидација и во фаза на

тестирање. Овој модел е особено погоден за моделирање на сложени, нелинеарни податоци со присутен шум, какви што се спектралните податоци од LPBF процесот.

- Исто така, овој модел има највисока брзина на предвидување во споредба со останатите модели, што го прави најефикасен без потреба од компромиси помеѓу точноста и брзината.
- Применета е PCA анализа како метод за ненадгледувано машинско учење со цел истражување на способноста за кластерирање на материјалите и нивната состојба со намалување на димензионалноста на влезните податоци.
 - PCA анализата покажа дека првата главна компонента објаснува 93.43% од варијансата, втората 3.95%, а останатите компоненти имаат занемарливо влијание ($<1\%$). Ова овозможи значително намалување на димензионалноста без загуба на важни информации.
 - Графикот на проектирани координати во дводимензионален простор дефиниран од првите два главни компоненти покажа формирање на четири јасни кластери кои одговараат на четирите дефинирани класи (2 материјали во 2 состојби).
 - При ниски енергетски влезови ($<0.05 \text{ J}$) беше забележано преклопување на кластерите поради слаб интензитет на сигнал, што ја покажува потребата од примена на техники за засилување на сигналот за зголемена чувствителност.
- Резултатите потврдуваат дека машинското учење може успешно да се интегрира во интелигентен OES мониторинг систем за LPBF процесот, овозможувајќи детекција на карактеристики и феномени во процесот.

7. РЕЗУЛТАТИ ОД ПРИМЕНАТА НА ФИЗИЧКИ ЗАКОНИ ПРИ СПЕКТРОСКОПСКА АНАЛИЗА ЗА МОНИТОРИНГ НА LPBF ПРОЦЕСОТ

Ова поглавје ги прикажува резултатите од примената на физичките закони врз спектралните податоци добиени преку коаксијален мониторинг на LPBF процесот. Емисиониот спектар што се регистрира за време на интеракцијата помеѓу ласерот и материјалот се состои од термичка радијација и од спектрални линии на легирачките елементи во металот, кои овозможуваат дополнителни физички анализи за карактеризација на процесот. За таа цел, презентирани се резултатите од примената на алгоритам за асиметрично измазнување со метод на најмали квадрати за изолирање на термичката радијација од спектралните линии.

Во продолжение се прикажани резултатите од примената на Виеновиот закон за поместување на зрачењето врз кривата на термичка радијација, со што квалитативно е проценета температурата на црното тело во зоната на обработка, споредбено за двата материјали и во функција на процесните параметри.

Конечно, демонстрирана е примената на методот на Болцманов график со користење на информациите од спектралните линии за квалитативна проценка и следење на трендот на температурата на електроните во плазмата.

Овие анализи ја надополнуваат емпириската анализа на машинското учење со физичка анализа и теоретска интерпретација на процесните состојби, при што се прикажува како физичките закони можат да се применат врз измерената спектрална емисија за набљудување на термичката динамика и состојбата на плазмата за време на ласерската обработка во LPBF процесот.

7.1. Изолирање на термичката радијација и спектралните линии од емисиониот спектар со примена на алгоритам за асиметрично измазнување со метод на најмали квадрати

Како што е теоретски објаснето во Поглавјето 3.6, спектралната емисија што се добива од зоната на интеракција помеѓу ласерскиот зрак и материјалот во процесот на LPBF претставува резултат на комбинација од два главни извори на зрачење кои сумирани го формираат регистрираниот спектар: термичката радијација и спектралните линии на легирачките елементи во металот. Секој од овие компоненти носи вредни информации за зоната и процесот на топење.

За да се овозможи детална анализа на овие компоненти, неопходно е нивно раздвојување и изолирање. Со примена на алгоритмот за асиметрично измазнување со метод на најмали квадрати (asymmetric least squares smoothing - ALsS) [198], се изолира термичката емисија, која се претставува како базна линија на спектралната емисија. Понатаму, базната линија се одзема од оригиналниот спектар, што овозможува изолирање на спектралните линии, односно карактеристичните емисии од легирачките елементи.

Алгоритмот ALsS беше имплементиран и целокупната анализа беше изведена со користење на програмскиот јазик MATLAB (The MathWorks Inc., Natick, Massachusetts, USA). Псевдо кодот на алгоритмот е прикажан подолу:

Функција БазнаЛинија(y , λ , p):

Влез:

y - низа со податоци (влезен спектар)

λ - параметар за измазнување

p - параметар за асиметрија

Иницијализација:

$m \leftarrow$ должина на y # Број на податочни точки

$D \leftarrow$ матрица на разлики од втор ред со големина m

$w \leftarrow$ низа од единици со големина m # Почетни тежини

За итерација = 1 до 10:

$W \leftarrow$ дијагонална матрица со тежини w

```
        C ← Холеска декомпозиција (Cholesky decomposition)
на
(W + λ * (D' * D)) # Декомпозиција на позитивно дефинирана
матрица
        z ← Реши го линеарниот систем користејќи C за z: (C
* C') * z = W * y
        Ажурирај тежини:
        w ← p * (y > z) + (1 - p) * (y < z) # Ажурирај
според тоа дали y е над или под z

Крај на функцијата со итерации

Излез:
        z - проценета базна линија
Крај на Функција БазнаЛинија
```

Во алгоритмот, влезните податоци y претставуваат спектрални податоци што се анализираат, додека параметрите λ и p имаат клучна улога во контролирање на измазнувањето и асиметријата на базната линија [198]. Алгоритмот се базира на итеративен процес кој вклучува:

1. Пресметка на тежини (w): Во секоја итерација, тежините се ажурираат врз основа на односот помеѓу тековната проценка на базната линија (z) и оригиналните податоци (y).
2. Решавање на линеарен систем: Процесот вклучува итеративно решавање на линеарен систем за проценка на базната линија z , каде тежините w и кривата се ажурираат. Почетно се применува измазнување со униформни тежини за да се добие првична проценка $\bar{z}$, по што новите тежини $\bar{w}$ се пресметуваат и системот се решава повторно.
3. Конвергирање: Овој процес се повторува 10 пати, бидејќи се покажа дека овој број на итерации е доволен за да се постигне конвергенција на решението.

Двата клучни параметри на алгоритмот λ и p мора внимателно да се изберат за да се прилагодат на специфичните податоци и да се добијат релевантни резултати:

- p : Овој параметар ја контролира асиметријата на базната линија. Авторите на алгоритмот препорачуваат вредности во интервалот $0.001 \leq p \leq 0.1$ [198].
- λ : Овој параметар го контролира измазнувањето на базната линија. Вредностите $10^2 \leq \lambda \leq 10^9$ се препорачани како опсег за прилагодување [198].

Номиналните вредности на параметрите беа одредени преку визуелна инспекција на резултатите добиени од различни комбинации на λ и p . Утврдено е дека најдобри резултати се постигнуваат со вредности $p = 0.001$ и $\lambda = 10^5$. Овие вредности овозможуваат точна изолација на термичката емисија и задоволителна идентификација на спектралните линии без значителни нарушувања или загуба на информации.


За да се прикаже резултатот од примената на овој алгоритам, на Слика 7.1 е прикажан пример за материјалот Ti-6Al-4V, добиен од експеримент со параметри $P = 200\text{ W}$ и $t_{on} = 800\text{ }\mu\text{s}$. Со сина боја е претставен коригираниот спектар на емисија. На овој спектар е применет алгоритмот ALsS, при што базната линија, која кореспондира со термичката радијација, е извлечена и прикажана со зелена боја. Термичката радијација претставува континуиран спектрален придонес што настанува како резултат на топлинската енергија генерирана за време на интеракцијата помеѓу ласерскиот зрак и материјалот. Оваа емисија е директна последица на загревањето на материјалот и се манифестира како мазна и континуирана позадина низ целиот спектрален опсег. Интензитетот на термичката радијација зависи од температурата на материјалот и неговите оптички својства. Анализата на оваа извлечена крива може да обезбеди информации за термичката состојба на зоната на обработка.

Откако термичката емисија е одземена од коригираниот спектар, се добива кривата на спектралните екстреми, која е претставена со црвена боја на Слика 7.1. Екстремите се уникатни за секој хемиски елемент и се резултат на електронски транзиции во атомите присутни во зоната на обработка. Теоретското објаснување на овој феномен и последиците кои проилегуваат се објаснети во Поглавје 3.6.1. Како резултат, се емитираат фотони на специфични бранови должини, карактеристични за легирачките елементи присутни во материјалот, кои спектрометарот ги регистрира.

Со примена на ALsS алгоритмот на спектралните податоци добиени од LPBF процесот, успешно беше изолирана термичката компонента како базна линија. Ова овозможува:

- Одредување на топлотните ефекти во процесната зона,
- Изолација на спектралните линии за карактеризацијата на плазмата.

Овој чекор е критичен за понатамошната анализа, бидејќи овозможува употреба на термичката базна линија за пресметка на температурата на црно тело со помош на законите на термичка радијација, а истовремено изолираните спектрални линии се користат за процена на температурата на електроните во плазмата во процесната зона преку Болцмановиот метод.




Слика 7.1: Резултат од примената на алгоритмот асиметрично измазнување со метод на најмали квадрати кај Ti-6Al-4V за изолирање на термичката радијација од спектарот и одвојување на кривата со спектрални екстрими, пример со $P=200W$ и $t_{on}=800\mu s$

7.2. Квалитативна проценка на температурата на црното тело во процесот LPBF со примена на Виеновиот закон за поместување на зрачењето

Со користење на Виеновиот закон за поместување на зрачењето, според равенката (3-90) и теоретското објаснување дадено во Поглавје 3.6.3, може да се пресмета температурата на "црното тело" врз основа на брановата должина со максимална вредност на интензитетот од кривата на термална радијација. Црното тело во процесот на LPBF претставува идеализиран модел на материјал кој апсорбира и емитира зрачење со максимална ефикасност, без никакви загуби или рефлексija. Во овој контекст, термичката емисија на материјалот, која е резултат на топлината генерирана од интеракцијата помеѓу ласерскиот зрак и материјалот, се користи како приближен модел за црно тело.

На Слика 7.2 се прикажани примери за извлечените базни линии за двата материјали што беа истражувани во експериментот. Прикажана е споредба помеѓу условите со најголем енергетски внес ($P = 200\text{ W}$ и $t_{on} = 800\mu\text{s}$) и најмал енергетски внес ($P = 100\text{ W}$ и $t_{on} = 200\mu\text{s}$), каде се демонстрирани варијациите во термичката радијација во зависност од параметрите на обработката.




Слика 7.2: Споредба на извлечени базни линии и нивното спектрално поместување при максимален и минимален енергетски внес на ласерот за: а) Ti-6Al-4V, и б) AISI316L

Со издвојувањето на базните линии и определување на брановата должина со максимален интензитет, а потоа нејзино користење во Виеновиот закон за поместување на зрачењето, беа пресметани теоретските проценки за температурите на црното тело ($T_{ц.т.}$) за сите експерименти. Резултатите се прикажани на Слика 7.3, каде што а) го прикажува Ti-6Al-4V, а б) го прикажува AISI316L. На графициите е прикажана варијацијата на теоретската проценка на температурата на црното тело во зависност од параметрите на моќноста (P) и времето на изложеност (t_{on}) на ласерот.

На графициите, точките ги претставуваат експерименталните податоци, додека со црвена боја е прикажана регресионата површина, а со сина боја е означен 95%

интервал на доверба за средната вредност на секоја група. Од податоците може да се забележи тренд на зголемување на теоретската температура на црното тело со зголемување на моќноста и времето на експозиција, што е директна последица на зголемениот енергетски внес на ласерот.



Слика 7.3: Моделирани регресиони површини за теоретската квалитативна проценка на температурата на црното тело ($T_{ц.т.}$) во функција од влезните параметри P и t_{on} за:
 а) Ti-6Al-4V, и б) AISI316L

За да се анализира зависноста на теоретската температура на црното тело од параметрите на процесот, спроведена е регресиона анализа, која резултираше со коефициенти на решителност $R^2 = 0.78$ за Ti-6Al-4V и $R^2 = 0.91$ за AISI316L.

Ваквите вредности укажуваат на висока согласност на регресионите модели со експерименталните податоци. Регресионите равенки за AISI316L е:

$$T [K] = 3906.8502 + 0.5560 \cdot t_{on} + 1.6282 \cdot P \quad (7-1)$$

а за Ti-6Al-4V е:

$$T [K] = 3923.0 + 1.2222 \cdot t_{on} + 8.01 \cdot P - 0.0006 \cdot t_{on}^2 - 0.0173 \cdot P^2 - 0.0026 \cdot t_{on} \cdot P \quad (7-2)$$

при што P се дефинира во $[W]$, а t_{on} во $[\mu s]$.

Од равенките може да се забележи дека равенката за AISI316L е линеарна, додека равенката за Ti-6Al-4V е полиномна од втор степен. Оваа разлика произлегува од различната термичка и физичка природа на материјалите. AISI316L, како нерѓосувачки челик, има поеднаква и попредвидлива реакција на енергетскиот внес, што резултира со линеарен тренд. Од друга страна, Ti-6Al-4V покажува посложени термички и физички интеракции, како што се фазни промени и различна топлинска спроводливост, што води кон нелинеарни ефекти.

Важно е да се напомене дека оваа анализа претставува само компаративна квалитативна анализа на трендот и релативните промени во температурата на црното тело, но не и квантитативна анализа. Проценетите температури не ја претставуваат точната вредност и не се потврдени со директни мерења или валидација. Сепак, резултатите се корисни за следење на трендот на температурата која се развива и за релативна анализа на параметрите на процесот.

Доколку постоеше можност за директно мерење на реалната температура на црното тело, ќе можеше да се одреди фактор на компензирање кој би ги коригирал пресметките за да се добијат точни и валидни вредности. За жал, таквата можност моментално не е достапна, поради што оваа анализа останува како квалитативна проценка за разбирање на трендовите и влијанието на процесните параметри врз термичките својства во LPBF процесот.

7.3. Идентификација и анализа на спектралните екстрими на легирачките елементи

Секој елемент во металната легура е поврзан со специфичен спектрален екстрем на одредена бранова должина. Анализата во овој дел од истражувањето беше насочена кон автоматска идентификација и визуелизација на релевантните екстрими во спектрите, од кои базната линија претходно беше одземена од коригираниот спектар. Оваа постапка е од суштинско значење за проценка на повторливоста на

системот за мониторинг при анализата на спектрите за ист материјал, како и за споредба на брановите должини на емисионите екстреми со оние што ги дефинира базата на атомски спектри на Националниот институт за стандарди и технологија [133].


За да се постигне ова, беше развиен алгоритам за детекција на екстреми во кривата. Алгоритамот за детекција на екстреми беше употребен за идентификација на локалните максимални точки врз основа на зададен праг за растојание и минимална висина на екстремите. Резултатите од оваа анализа се прикажани на Слика 7.4, каде што се илустрирани брановите должини на детектираните екстреми во спектрите добиени од изведените експерименти. Од овие резултати беа исклучени експериментите кои не резултираа со стопен регион, бидејќи тие покажаа отсуство на значајно зголемување на сигналот во спектарот.

На сликата е прикажан пример за спектар по одземање на базната линија за двата материјали во опсегот од 400 до 800 nm, кој е добиен од експеримент со ласерска моќност од 200 W и време на изложеност од 800 μ s. На овој спектар се назначени и идентификуваните спектрални екстреми со користење на информациите од базата на податоци на NIST [133]. Во случајот на AISI316L, беа идентификувани повеќе екстреми што кореспондираат со базниот елемент железо (Fe), како и со легирачките елементи хром (Cr) и никел (Ni). За легурата Ti-6Al-4V, спектралната анализа откри екстреми кои се поврзани со титаниум (Ti), елементот со највисока концентрација во легурата, како и со алуминиум (Al) и ванадиум (V). Во процесот на анализа беше забележано дека одредени спектрални екстреми не се детектирани од алгоритамот во некои од спектрите, додека во други случаи се појавуваат дополнителни екстреми. Оваа појава е особено изразена при анализа на нискоинтензитетни екстреми кај материјалот AISI316L, што може да се должи на варијации во емисијата при ниски интензитети или на ограничувања во чувствителноста на алгоритамот за детекција на екстреми.

Иако генерално се концентрирани околу очекуваните вредности, сепак се забележуваат варијации во брановата должина на спектралните екстреми низ различните експерименти, особено изразени кај AISI316L, кои се резултат на повеќе физички фактори. Еден од главните фактори е Доплеровото проширување на спектралните линии, кое се јавува поради топлинското движење на честичките, што предизвикува мали поместувања на брановата должина [199]. Старковото проширување како последица на интеракциите меѓу емитувачките атоми и околните наелектризирани честички, може да предизвика дополнителни поместувања и ширење на линиите, особено во високо-енергетски процеси како што е LPBF [200]. Самоапсорпцијата во плазмата може да доведе до мали поместувања или слабеење на одредени линии [201]. Овие потенцијални фактори може да доведат до тоа спектралните екстреми да не се совпаѓаат совршено низ сите експерименти, туку да

покажуваат мали отстапувања околу нивната очекувана бранова должина, што се гледа на сликата.

И покрај овие варијации, екстремите што се појавуваат во најголем дел од експериментите покажуваат усогласеност со брановите должини кои кореспондираат со легирачките елементи, документирани во NIST. Ова укажува на тоа дека идентификуваните екстрими се директно поврзани со составните карактеристики на металните легури, обезбедувајќи вредни информации за нивниот хемиски состав. Овие резултати ја потврдуваат ефикасноста на развиениот систем за OES мониторинг во детекцијата на спектралните емисиони екстрими кои се карактеристични за легирачките елементи на анализираните материјали.



Слика 7.4: Бранови должини на детектираните спектрални екстрими во експериментите и крива на спектрални екстрими од експеримент со $P=200W$ и $t_{on}=800\mu s$, со означени спектрални екстрими на легирачките елементи идентификувани според NIST [133], за: а) AISI316L; б) Ti-6Al-4V.

7.4. Квалитативна проценка на температурата на електроните во плазмата во процесот LPBF со примена на методот на Болцманов график

Методот претпоставува дека електроните во плазмата се распределени според Болцмановата распределба, при што логаритамот на нормализираниот интензитет на секоја спектрална линија е линеарно зависен од енергијата на горното ниво на транзицијата. За да се постигне квалитативна проценка на температурата на електроните, неопходно е да се користат најмалку три јасно разликувани и оптички тенки линии кои припаѓаат на ист елемент и иста јонизациска состојба и да покриваат што поширок енергетски опсег на горните нивоа (E_k). Теоретската основа на овој метод за анализа, како и дефиниција и ознака на параметрите кои ги сочинува е дадена во Поглавје 3.6.4.

За да се изврши квалитативната проценка на температурата на електроните преку методот на Болцманов график, беа селектирани спектрални линии на легирачките елементи во двата анализирани материјали: FeI за AISI 316L и TiI за Ti-6Al-4V. Избраните спектрални линии се доминантни екстреми во емисионите спектри дадени на Слика 7.4, припаѓаат на иста јонизациска состојба, и се намерно одбрани за да се опфати поширок енергетски опсег на горните енергетски нивоа за да се овозможи статистички подоверлива линеарна регресија. Во Табела 7-1 за AISI316L и Табела 7-2 за Ti-6Al-4V се прикажани избраните спектрални линии и нивните карактеристики: бранова должина (λ), енергија на горното ниво (E_k), веројатност за преод (A_{ki}), и дегенерација на горното ниво (g_k).

Табела 7-1: Избрани спектрални линии за примена на метод на Болцманов график и нивни карактеристики за AISI316L


Елемент	λ [nm]	E_k [eV]	A_{ki} [s^{-1}]	g_k
Fe I	403.263	4.558	246000	700
Fe I	425.934	5.900	234000	900
Fe I	592.779	6.743	5400000	300

Табела 7-2: Избрани спектрални линии за примена на метод на Болцманов график и нивни карактеристики за Ti-6Al-4V

Елемент	λ [nm]	E_k [eV]	A_{ki} [s^{-1}]	g_k
Ti I	428.498	4.632	32000000	500
Ti I	500.965	2.495	241000	700
Ti I	591.853	3.161	1300000	500



Добиените резултати од квалитативната проценка на температурата на електроните во плазмата со примена на методот на Болцманов график се прикажани на графици

на интервали Слика 7.5, под а) за AISI 316L и под б) за Ti-6Al-4V. Од графициите може да се забележи зависност на температурата на плазмата од процесните параметри, односно покажано е дека со зголемување на ласерската моќност и времето на изложеност се зголемува и теоретски пресметаната температура. Важно е да се напомене дека методот е применет за квалитативна проценка на температурата на електроните во плазмата и за следење на релативни трендови при промена на процесните параметри, а не за добивање на апсолутни (квантитативни) вредности. Дополнително, кај некои параметарски комбинации може да се забележи поголема стандардна девијација, што најверојатно се должи на физички феномени на проширување на спектралните линии, што е очекувано во процес со висока енергија.



Слика 7.5: Резултати од квалитативната проценка на температурата на електроните во плазмата со примена на методот на Болцманов график во зависност од процесните параметри: а) AISI316L; б) Ti-6Al-4V

За споредба на изгледот на регресионата крива добиена од Болцмановиот график, односно на температурата на електроните која е пропорционална со инверзниот наклон на линеарната регресиона линија, на Слика 7.6 се прикажани резултатите за двата материјали при иста комбинација на процесни параметри ($P = 100\text{ W}$ и $P = 200\text{ W}$, при $t_{on} = 200\text{ }\mu\text{s}$). Може да се забележи дека зголемувањето на влезната енергија резултира со промена на наклонот на регресионата линија и, соодветно, со повисока проценета температура на плазмата. Високите вредности на коефициентот на решителност, кои на прикажаните примери се движат од 0.915 до 0.999, укажуваат на добра линеарна корелација и висока точност при моделирањето.



Слика 7.6: Примери од линеарна регресиона линија и проценета температура на електроните во плазмата според Болцмановиот график: а) AISI316L; б) Ti-6Al-4V

7.5. Заклучоци за поглавјето

По успешната примена на машинско учење во претходните анализи, во ова поглавје беше истражена способноста за примена на физички закони од областа на спектроскопијата врз спектралните податоци од коаксијалниот OES мониторинг систем во LPBF процесот, за квалитативно следење и подлабока интерпретација на термичките појави во зоната на обработка. Од истражувањето произлегоа следните технички и научни резултати:

- Спектралната емисија од зоната на интеракција помеѓу ласерот и материјалот ги сумира ефектите од термичка радијација и емисиони линии на легирачките елементи, кои содржат значајни информации за термичките услови и хемискиот состав на зоната на топење.
- За нивно раздвојување беше имплементиран алгоритам за асиметрично измазнување со метод на најмали квадрати (ALsS), со оптимални параметри $p = 0.001$ и $\lambda = 10^5$, кој овозможи успешно изолирање на базната линија (термичка емисија) и издвојување на спектралните линии.
- Издвоената термичка компонента беше искористена за квалитативна проценка на температурата на црното тело со примена на Виеновиот закон, при што беа добиени регресиони модели со висока точност ($R^2 = 0.91$ за AISI316L, $R^2 = 0.78$ за Ti-6Al-4V) во функција од влезните параметри. За AISI316L е добиена линеарна зависност, додека за Ti-6Al-4V полиномна од втор степен што произлегува од различните термо-физички својства на материјалите.
- Развиен е алгоритам за автоматска идентификација на спектралните екстреми на легирачките елементи според информациите во Atomic Spectra Database на NIST, што овозможи детекција на карактеристични линии за Fe, Cr, Ni кај AISI316L и Ti, Al, V кај Ti-6Al-4V, со што се потврди дека имплементираниот OES мониторинг систем може прецизно да ги следи промените во составот.
- Забележани се мали варијации на брановите должини на спектралните екстреми на легирачките елементи помеѓу различните експерименти, предизвикани од физички феномени како Доплерово и Старково проширување и самоапсорпција, што е очекувано во високо-енергетскиот LPBF процес.
- Изолираните спектрални линии беа основа за примена на методот на Болцманов график за квалитативна проценка на температурата на електроните во плазмата. Соодветни спектрални линии на ист елемент и иста

јонизациска состојба во поширок енергетски опсег на горните нивоа беа избрани со цел да се добијат линеарни корелации со висок коефициент на решителност. Резултатите покажаа зависност на квалитативно проценетата температура на електроните во плазмата од ласерската моќност и времето на изложеност, при што зголемувањето на овие параметри води до повисоки температури во плазмата. Кај некои параметарски комбинации се забележа поголема стандардна девијација, што најверојатно се должи на физички феномени на проширување на спектралните линии.

8. ДИСКУСИИ

8.1. Дискусија за примената на мониторинг системот и експерименталната методологија

Користената експериментална платформа е отворен тип на LPBF систем, што овозможи прилагодливост за интеграција на сензорскиот систем и изведување на контролирани експерименти. Методологијата беше испитана со стратегија на единечна точка на изложеност, која често се применува за изработка на фини решеткести структури, овозможувајќи висока прецизност благодарение на малата големина на ласерскиот зрак.

Во дефинираните услови, предложената методологија покажа успешност и демонстрира дека може да обезбеди стабилност на процесот при изработка на решеткести структури со LPBF. Сепак, потребно е понатамошно истражување за да се оцени дали и како бројот на слоеви влијае на сигналот. Понатамошните истражувања треба да ги опфатат стратегиите на скенирање базирани на вектори и да се разгледаат тридимензионални структури со повеќе слоеви, каде што термичката интеракција меѓу слоевите може да влијае врз спектралниот сигнал. Понатамошни истражувања треба да вклучат различни материјали и да се испита дали нивната спектрална емисија при ласерска обработка може да биде регистрирана со сензорот за оптичка емисиона спектроскопија.

Важно е да се истакне дека оптичката емисиона спектроскопија, иако нуди вредни информации за емисиите од површината на материјалите и пламата предизвикана од ласерот, не обезбедува сеопфатен поглед во длабочината на зоната на топење и во внатрешната структура на материјалот што се обработува. Тоа значи дека информации за порозност, микроструктура или механички својства не можат да се добијат само од OES податоците. Ова може да биде ограничување при обидите за разбирање на целосните карактеристики на материјалот за време на LPBF процесот. Дополнително, на спектралната емисија може влијаат фактори како промени во аголот на опсервација, рефлексивност од површината, или промени во помошниот гас кој се користи во процесот.

И покрај овие ограничувања, истражувањето ја демонстрираше значајноста на оптичката емисиона спектроскопија за мониторинг и разбирање на LPBF процесот, анализирајќи широк спектар на емитувани бранови должини кои обезбедуваат директен увид во процесните услови.

8.2. Дискусија за примената на моделите со машинско учење

Моделите со машинско учење во ова истражување беа развиени и обучени врз основа на експериментални податоци добиени од обработка на двете метални легури AISI 316L и Ti-6Al-4V, при што резултатите покажаа висока точност при класификација на материјалот и детекција на појава на денудација, како и за предвидување на големината на стопената зона при интеракцијата на ласерот и материјалот во процесот на печатење со LPBF. Сепак, употребливоста на овие емпириски модели е ограничена на материјалите за кои се обучени. За да се прошири нивната примена на други легури, потребно е повторно тренирање на моделите со експериментални спектрални податоци собрани за време на обработката на конкретниот материјал.

Како пример за времињата на тренирање на моделите со машинско учење, тренирањето на моделот k -најблиски соседи за класификација со даденото множество на податоци траеше 2.56 секунди, додека тренирањето на моделот за регресија со Гаусов процес за истите податоци траеше 5.18 секунди. Важно е да се напомене дека времето за тренирање расте со зголемување на димензионалноста и обемот на податочното множество.

Презентирираниот мониторинг пристап со машинско учење овозможува начин за мониторинг во реално време на појавата на дефекти и потенцијална повратна врска преку користење на спектралните податоци, со што се поставува основата за интелигентен LPBF систем. Дополнително, способноста за идентификација на материјалот за време на изработката овозможува автоматска оптимизација на параметрите кога материјалите се разликуваат низ слоевите во печатениот дел. Сепак, постојат одредени ограничувања на предложениот пристап кои треба да се земат во предвид. Моментално користената програмска средина, MATLAB (The MathWorks Inc., Natick, Massachusetts, USA), постигна време на предвидување од приближно $2\ \mu s$ за обработка на еден спектар со двата модели за машинско учење. Ова време може да се намали со користење на контролери кои можат да се поврзат со спектрометарот при што анализата ќе се изврши во самиот контролер. Дополнително, времето за интеграција на користениот спектрометар изнесува $10\ ms$, што ја лимитира максималната фреквенција на аквизиција и брзината на реакција на системот. Брзите прилагодувања кои се потребни за време на LPBF процесот за одржување на посакуваните процесни услови ја ограничуваат применливоста на OES сензорите за оваа намена, особено во споредба со сензори со повисока фреквенција на аквизиција, како што се фотодиоди и високо-фреквентни

камери. За да се имплементира систем за контрола во реално време, овие времиња треба да се минимизираат.

8.3. Дискусија за примената на физичките закони во спектроскопијата

Во рамките на ова истражување, физичките закони се применети со цел да се добие подлабоко разбирање за термичката состојба на процесот во LPBF, базирано на спектралните податоци добиени преку коаксијален мониторинг. Спроведената анализа опфати изолирање на компонентите на термичка радијација и спектралните линии преку алгоритам за асиметрично измазнување со метод на најмали квадрати, по што беа применети Виеновиот закон за проценка на температурата на црното тело и методот на Болцманов график за квалитативна проценка на температурата на електроните во плазмата.

Резултатите покажуваат кохерентни трендови што ја следат очекуваната физичка логика: повисоки температури на црното тело и на електроните во плазмата се добиваат при повисоки вредности на внесена енергија (поголема моќност и/или подолго време на изложеност) при што се забележува и разлика во термичката реакција на различните материјали. Така, за Ti-6Al-4V беа добиени повисоки температури на црното тело при исти енергетски параметри, што може да се припише на понискиот коефициент на топлинска спроводливост и поголемата способност за апсорпција на енергијата на ласерската бранова должина во споредба со AISI316L.

Важно е да се нагласи дека сите добиени резултати од примената на физичките закони се квалитативни и служат за идентификување на трендови и споредбени анализи, а не за апсолутно мерење на температури. Проценетите температури не ја претставуваат точната вредност и нема референтен сензор за температура (на пример пирометар или термографска камера) кој би овозможил валидација и калибрација на добиените температурни вредности.

Во процесот на анализа на податоците со физичките закони треба да се напоменат неколку фактори кои можат потенцијално да влијаат на прецизноста на резултатите. Прво, во алгоритмот за асиметрично измазнување параметрите се калибрираат визуелно, што внесува субјективност и потенцијална варијабилност. Второ, се претпоставува локална термодинамичка рамнотежа и оптичка тенкост на спектралните линии, кои во реални услови може да не се целосно валидни. Дополнително, при примената на Болцмановиот график, точноста на регресионата права и со тоа на проценката на температурата значително зависи од изборот, бројот

и распоредот на спектралните линии што припаѓаат на иста јонизациска состојба, како и од точноста на нивните параметри превземени од базата на NIST (A_{ki} , g_k , E_k).

И покрај наведените ограничувања, примената на физичките закони во ова истражување претставува значаен придонес: покажува дека спектралните податоци содржат доволно физички информации за да се следат процесните состојби и без експлицитно обучен емпириски модел, како што е машинското учење. Овие резултати отвораат можност за комбиниран пристап каде физичките закони обезбедуваат основа за теоретски валидна интерпретација, а машинското учење овозможува автоматизирано предвидувања на феномени.

8.4. Дискусија за хибриден интелигентен мониторинг систем со синергетска примена на физички модели и машинско учење во LPBF

Истражувањето демонстрира дека паралелната примена на физички закони и алгоритми за машинско учење во анализа на спектрални податоци од LPBF процесот овозможува комплементарна интерпретација на термичките и структурните феномени што се јавуваат при ласерското топење на металниот прав во процесот LPBF. Иако овие методолошки пристапи се концептуално различни - физиката се темели врз аналитички закони, додека машинското учење користи емпириски модели базирани на податоци - нивната интеграција носи потенцијал за синергетска анализа и зголемена доверливост во мониторингот.

Методот на анализа на податоците со физичките закони овозможува теоретски заснована анализа на термичката емисија, температурни трендови и споредбени анализи помеѓу различни легури и процесни параметри. Овој метод е посебно корисен при иницијална карактеризација на процесот, бидејќи не бара големи количини на податоци или претходно обучени модели. Но, методот претпоставува постоење на локална термодинамичка рамнотежа и оптичка тенкост на спектралните линии, и со тоа нивната применливост станува ограничена поради потребата од идеализирани претпоставки, прецизна селекција на спектралните емисиони линии и калибрирани оптички параметри.

Методот на анализа со примена на машинско учење базира на автоматизирано препознавање на шеми и релации во податоците, способни за обработка на големи количини на податоци со висока брзина. Сепак, овие модели се емпириски и валидни само во рамките на доменот на услови и материја на кои се обучени и покажуваат ограничена способност за генерализација без повторна обука.

Комбинираниот пристап се појавува како ефикасен методолошки концепт кој ги обединува аналитичката прецизност на физичките закони и предвидувачката моќ на машинското учење. Примената на физички модели може да се искористи за селекција и филтрација на значајни спектрални емисиони линии и карактеристики, што овозможува намалување на димензионалноста и зголемена робусност на моделите со машинско учење. Дополнително, резултатите од физичките модели можат да се користат како дополнителни влезни параметри во хибридни архитектури со машинско учење, со што се надминува емпириската природа на алгоритмите и се зголемува нивната доверливост.

Оваа синергетска примена отвора можност за развој на хибридни интелигентни мониторинг системи, каде што интерпретацијата е физички валидирана, а предвидувањето и реакцијата на процесот се изведуваат со висока брзина и автоматизација. Со дополнителна интеграција на контрола во реално време на параметрите во процесот, ваквите системи би можеле да придонесат за зголемен квалитет на изработените компоненти, како и за поширока примена на LPBF технологијата во индустриски услови.

9. ЗАКЛУЧОЦИ И НАСОКИ ЗА ИДНИ ИСТРАЖУВАЊА

9.1. Заклучоци од осознавачки карактер

Во оваа докторска дисертација се развива интелигентен систем за мониторинг за процесот на ласерска фузија на слој од прав (LPBF) за адитивно производство на делови од метал, преку интеграција на оптичка емисиона спектроскопија (OES) и методи на машинско учење. Мотивацијата произлегува од потребата за добивање увид во зоната на интеракција помеѓу ласерот и материјалот, со цел следење на стабилноста на процесот и навремено препознавање на условите што водат до формирање на дефекти. Во рамки на истражувањето, применет е аналитички пристап кој комбинира емпириска анализа со алгоритми за машинско учење и теоретска анализа заснована на фундаментални физички закони во спектроскопијата, со цел да се овозможи автоматизирано предвидување на процесни феномени и истовремено да се постигне подлабоко, научно засновано разбирање на процесот преку анализа на спектралните информации. Имплементираната методологија беше испитувана при услови на стратегија на единечна точка на изложеност на ласерот, која е релевантна и применувана за изработка на решеткасти структури со фини геометрии и тенки столбови, каде што стабилноста на процесот и контролата на топењето се од суштинско значење. Алгоритмите со машинско учење се применети за детекција на дефектот на денудација, идентификација на материјалот што се печати, и за проценка на дијаметарот на тенките столбови во решеткастите структури; додека анализата базирана на физички закони овозможува следење на температурната динамика на процесот, преку квалитативна проценка на температурата на црното тело и температурата на електроните во плазмата. Сензорот за оптичка емисиона спектроскопија овозможува анализа на сите поставени цели со само еден сензор, за разлика од традиционалните методи за мониторинг, бидејќи овозможува истовремено набљудување на интензитетот на топење и на спектралните карактеристики на емитираната светлина, преку кои може да се изведат информации за хемискиот состав на материјалот.

9.2. Заклучоци од мериторен карактер

Во докторската дисертација успешно беа остварени сите поставени цели, при што преку нивното исполнување се потврдија и трите поставени хипотези, односно дека: 1) оптичката емисиона спектроскопија може ефикасно да се интегрира во LPBF процесот за следење на процесните услови во реално време, овозможувајќи набљудување на зоната на топење и хемискиот состав на материјалот кој се печати во реално време; 2) алгоритми за надгледувано машинско учење со класификација и регресија и алгоритми за ненадгледувано машинско учење со анализа на главни компоненти можат со висока точност да го идентификуваат материјалот кој се печати, да ја детектираат појавата на денудација и да вршат проценка на дијаметрите на тенките столбови од решеткастите структури изградени со стратегија на единечна точка на изложеност; 3) примената на физички закони врз спектралните податоци овозможува добивање на квалитативна слика за термичкиот интензитет на процесот и разбирање на динамиката на топење.

За верификација на првата хипотеза беше реализиран целосен систем за мониторинг со OES, коаксијално интегриран во оптичкиот пат на LPBF машината. Развиени беа два модели на поставување: коаксијален и надвор од оптичкиот пат на ласерот, при што вториот се користеше исклучиво за откривање на преносната функција на оптичките елементи во главата за скенирање, што потоа се користи за корекција на добиените спектрални сигнали. Беше воспоставена синхронизација помеѓу машината и системот за снимање, што овозможи снимање на спектралните податоци токму во моментот на интеракција помеѓу ласерот и правот.

За да се создаде база на експериментални податоци погодна за понатамошна анализа, беше спроведен експеримент со четири променливи фактори: тип на материјал (AISI 316L и Ti-6Al-4V, избрани поради нивната широка индустриска примена и честата употреба при изработка на решеткасти структури со адитивно производство на метал), состојба на материјалот (прашката и во полн материјал за да се симулира дефектот на денудација), ласерска моќност (P), и време на изложеност на ласерот (t_{on}), при што последните два фактори беа менувани на три различни нивоа. На добиените податоци од експериментите беше извршена статистичка анализа со цел да се испита зависноста на резултатите од избраните фактори и да се потврди дека развиениот и имплементираните мониторинг систем за OES е способен да ги регистрира и следи промените и варијациите во процесот.

Истражувањето понатаму се насочи кон верификација на втората хипотеза, односно кон примена на алгоритми за машинско учење за анализа на спектралните податоци добиени од LPBF процесот, при што беа развиени и споредени пет модели за класификација и пет модели за регресија. Моделите за класификација беа користени

за идентификација на материјалот што се печати и за детекција на појавата на дефектот денудација. Од тестираните модели, алгоритмот k -најблиски соседи постигна највисока точност на предвидување, со 93.6% точност во фаза на валидација и 95.2% при тестирање. Но, неговото време на предвидување е значително подолго во споредба со другите модели, односно се добиваат помал број на предвидувања во секунда. Од аспект на ефикасност, најдобро се покажа моделот базиран на машини со носечки вектори, кој иако има нешто пониска точност споредбено со k -најблиски соседи (помала за околу 5% при фазата на валидација), сепак прави скоро двојно повеќе предвидувања во секунда. Ова укажува дека во апликации каде што времето на предвидување е критично, моделот на машини со носечки вектори може да биде попогоден избор, прифаќајќи мал компромис во точноста.

Во однос на регресионите модели, тие беа користени за проценка на дијаметарот на стопената зона, кој е адекватен на дијаметарот на тенките столбови кога решеткастата структура се печати со стратегија на единечна точка на изложеност. Овој излез, освен за големината на зоната на топење, служи како индикатор за влезот на енергија во процесот и стабилноста на топењето. Доколку топената зона е значително помала или поголема од очекуваниот номинален опсег, тоа може да укаже на несоодветен внес на ласерска енергија, што потенцијално води до појава на дефекти и намалена структурна стабилност на изработениот дел. Од петте тестирани модели за регресија, најдобри перформанси покажа моделот за регресија базиран на Гаусов процес, со R^2 вредност од 92% при валидација и 95% при тестирање. Во исто време овој модел резултираше и со највисока брзина на предвидување споредбено со другите модели, што го прави најсоодветен за практична примена.

Дополнително, во истражувањето беше вклучена и анализа со ненадгледувано машинско учење преку примена на анализа на главни компоненти. Резултатите покажаа јасно кластерирање на различните типови на материјали и нивните состојби со значително намалување на димензионалноста на влезните податоци, притоа задржувајќи ги клучните информации, со што се покажа дека оваа анализа може да биде корисна алатка за почетна анализа и визуелизација на податоците.

За проучување на третата хипотеза беа применети физички закони со цел подлабоко разбирање и објаснување на термичките појави што се одвиваат при ласерската обработка во процесот LPBF. Преку изолирање на термичката радијација од емисиониот спектар со примена на алгоритам за асиметрично измазнување со метод на најмали квадрати, и последователна примена на Виеновиот закон за поместување на зрачењето, беше извршена квалитативна проценка на температурата на црното тело во функција од видот на материјалот и процесните параметри. Проценетата температура на AISI316L беше моделирана со линеарна регресија со точност од

91%, додека кај Ti-6Al-4V беше применет полином од втор степен со точност од 78%, поради сложената термичка интеракција, различната топлинска спроводливост и фазните трансформации кои го отежнуваат опишувањето со линеарен модел.

Преку споредба со базата на атомски спектри на Националниот институт за стандарди и технологија, беше потврдено дека спектралните линии забележани во емисиониот спектар одговараат на легирачките елементи во металите, со што се валидираше точноста на сигналите и функционалноста на мониторинг системот. За проценка на температурата на електроните во плазмата, беше применет Болцмановиот график врз основа на избрани спектрални линии од иста јонизациска состојба. Резултатите покажаа дека температурата на плазмата зависи од вредноста на процесните параметри, односно дека со зголемување на ласерската моќност и времето на изложеност се зголемува и теоретски пресметаната температура. Сепак, резултатите покажаа релативно повисока стандардна девијација што најверојатно се должи на физичкиот феномен на проширување на спектралните линии кај високо-енергетски процеси како што е LPBF процесот што влијае на резултатот кој се добива од анализата.

9.3. Заклучоци од утилитарен карактер

Истражувањето претставува значаен технички и научен придонес кон развојот на интелигентни системи за мониторинг на LPBF процесот, преку интеграција на оптичка емисиона спектроскопија, алгоритми за машинско учење и физички закони. Со тоа се креира интелигентна машина која е способна автономно да го следи процесот во реално време, да препознае промени во процесните услови и да донесува одлуки базирани на анализата на спектрални податоци. Предложената методологија придонесува кон зголемена автоматизација и контрола, и подобрен квалитет на финалните производи, особено при изработка на комплексни геометрии како решеткастите структури. Овие резултати го поддржуваат поширокото прифаќање и примена на адитивното производство во индустриски сектори со високи технички барања, како воздухопловството, автомобилската индустрија, биомедицината и енергетиката, каде решеткастите структури се често користени и нивната изработка е возможна исклучиво со адитивно производство.

9.4. Насоки за идни истражувања

Врз основа на добиените резултати и идентификуваните ограничувања, се отвораат неколку насоки за понатамошно продлабочување на истражувањето и проширување на примената на развиениот мониторинг систем.

1. Една од насоките која значително ќе придонесе кон пошироко прифаќање на LPBF процесот и општо технологиите на адитивно производство за делови од метал, е развојот на систем за контрола на параметрите во реално време врз основа на обработката на мониторинг податоци (во овој случај, на спектрални податоци). Иако ова докторско истражување демонстрира успешна детекција на варијации во процесот, имплементација на затворена врска за контрола бара дополнително скратување на времето на аквизиција на сензорот и на предвидување со моделите на машинско учење, како и интеграција со контролниот модул на LPBF машината. Таквиот систем би овозможил адаптација на параметрите на ласерот во реално време во зависност од мониторинг сигналите, со цел одржување на номинални стабилни услови и минимизирање на дефекти.
2. Друга насока е проширување на машинското учење со техники на длабоко учење. Во ова истражување беа применети класични модели за машинско учење. Идни истражувања може да вклучат архитектури базирани на длабоки невронски мрежи (како конволуциска невронска мрежа или невронска мрежа со долга краткорочна меморија) со кои потенцијално може да се моделира временската зависност и комплексните зависимости во спектралните податоци.
3. Како трета насока, се наметнува потребата од фузија на податоци од повеќе сензори. Иако OES обезбедува богат спектар на информации, неговото комбинирање со други видови на сензори, како фотодиоди, термографски камери или акустични сензори, може да овозможи посеопфатна проценка на состојбата на процесот. Овој мултисензорски пристап може да доведе до понапредни интелигентни системи за следење и дијагностика.
4. Конечно, може да се развие отворена база на спектрални податоци за LPBF. Потребата за големи и квалитетни множества на податоци е клучна за развој и валидација на модели со машинско учење. Креирање и ажурирање на отворена база на спектрални емисии со ознаки за материјал, параметри, дефекти, и други услови на процесот може да помогне во стандардизирање и споредба на модели меѓу различни истражувачки групи и индустрии.

Користена литература

- [1] O. Abdulhameed, A. Al-Ahmari, W. Ameen, and S. H. Mian, “Additive manufacturing: Challenges, trends, and applications,” *Advances in Mechanical Engineering*, vol. 11, no. 2, p. 1687814018822880, Feb. 2019, doi: 10.1177/1687814018822880.
- [2] International Organization for Standardization, “Additive manufacturing — General principles — Fundamentals and vocabulary (ISO Standard No. 52900:2021),” 2021, <https://www.iso.org/standard/74514.html>.
- [3] I. Gibson, D. Rosen, B. Stucker, and M. Khorasani, “Powder Bed Fusion,” in *Additive Manufacturing Technologies*, I. Gibson, D. Rosen, B. Stucker, and M. Khorasani, Eds., Cham: Springer International Publishing, 2021, pp. 125–170. doi: 10.1007/978-3-030-56127-7_5.
- [4] R. Singh *et al.*, “Powder bed fusion process in additive manufacturing: An overview,” *Mater Today Proc*, vol. 26, pp. 3058–3070, 2020, doi: <https://doi.org/10.1016/j.matpr.2020.02.635>.
- [5] S. Sels, B. Bogaerts, S. Vanlanduit, and R. Penne, “Extrinsic calibration of a laser galvanometric setup and a range camera,” *Sensors (Switzerland)*, vol. 18, no. 5, May 2018, doi: 10.3390/s18051478.
- [6] T. Duda and L. V. Raghavan, “3D metal printing technology: the need to re-invent design practice,” *AI Soc*, vol. 33, no. 2, pp. 241–252, May 2018, doi: 10.1007/s00146-018-0809-9.
- [7] H. Sonar, S. Ghosh, R. K. Singh, V. Khanzode, M. Akarte, and N. Ghag, “Implementing Additive Manufacturing for Sustainability in Operations: Analysis of Enabling Factors,” *IEEE Trans Eng Manag*, vol. 71, pp. 3205–3219, 2024, doi: 10.1109/TEM.2022.3206234.
- [8] S. L. Sing and W. Y. Yeong, “Laser powder bed fusion for metal additive manufacturing: perspectives on recent developments,” *Virtual Phys Prototyp*, vol. 15, no. 3, pp. 359–370, Jul. 2020, doi: 10.1080/17452759.2020.1779999.
- [9] M. T. Getachew, M. Z. Shiferaw, and B. S. Ayele, “Recent Advances of Additive Manufacturing for Aerospace Industries: Methods, Materials, Challenges, and Future Outlooks,” in *Sustainable Development Research in Manufacturing, Process Engineering, Green Infrastructure, and Water Resources: Advancement of Science and Technology*, S. W. Fanta, M. W. Tenagashaw, M. T. Tigabu, and E. Y. Gedilu, Eds., Cham: Springer Nature Switzerland, 2025, pp. 47–82. doi: 10.1007/978-3-031-77339-6_4.

- [10] A. H. Alami *et al.*, “Additive manufacturing in the aerospace and automotive industries: Recent trends and role in achieving sustainable development goals,” *Ain Shams Engineering Journal*, vol. 14, no. 11, p. 102516, 2023, doi: <https://doi.org/10.1016/j.asej.2023.102516>.
- [11] S. G. Jeong *et al.*, “Prototyping of nuclear fuel assembly parts by laser powder bed fusion of Inconel 718,” *Progress in Nuclear Energy*, vol. 184, p. 105694, 2025, doi: <https://doi.org/10.1016/j.pnucene.2025.105694>.
- [12] R. Kumar, M. Kumar, and J. S. Chohan, “The role of additive manufacturing for biomedical applications: A critical review,” *J Manuf Process*, vol. 64, pp. 828–850, 2021, doi: <https://doi.org/10.1016/j.jmapro.2021.02.022>.
- [13] J. Ye *et al.*, “3D printed porous magnesium metal scaffolds with bioactive coating for bone defect repair: enhancing angiogenesis and osteogenesis,” *J Nanobiotechnology*, vol. 23, no. 1, p. 160, 2025, doi: [10.1186/s12951-025-03222-3](https://doi.org/10.1186/s12951-025-03222-3).
- [14] M. Grasso and B. M. Colosimo, “Process defects and *in situ* monitoring methods in metal powder bed fusion: a review,” *Meas Sci Technol*, vol. 28, no. 4, p. 044005, 2017, doi: [10.1088/1361-6501/aa5c4f](https://doi.org/10.1088/1361-6501/aa5c4f).
- [15] B. Brandau, A. Da Silva, C. Wilsnack, F. Brueckner, and A. F. H. Kaplan, “Absorbance study of powder conditions for laser additive manufacturing,” *Mater Des*, vol. 216, p. 110591, 2022, doi: <https://doi.org/10.1016/j.matdes.2022.110591>.
- [16] B. C. dos S. Silva *et al.*, “Investigation of Distortion, Porosity and Residual Stresses in Internal Channels Fabricated in Maraging 300 Steel by Laser Powder Bed Fusion,” *Materials*, vol. 18, no. 5, p. 1019, Feb. 2025, doi: [10.3390/ma18051019](https://doi.org/10.3390/ma18051019).
- [17] S. Lu *et al.*, “Influence of process parameters on the microstructures, residual stresses and mechanical properties of TA15 titanium alloy fabricated by L-PBF,” *Materials Science and Engineering: A*, vol. 927, p. 147990, 2025, doi: <https://doi.org/10.1016/j.msea.2025.147990>.
- [18] E. Vasileska, A. G. Demir, B. M. Colosimo, and B. Previtali, “Layer-wise control of selective laser melting by means of inline melt pool area measurements,” *J. Laser Appl.*, vol. 32, no. 022057, 2020, doi: doi.org/10.2351/7.0000108.
- [19] E. Malekipour and H. El-Mounayri, “Common defects and contributing parameters in powder bed fusion AM process and their classification for online monitoring and control: a review,” *International Journal of Advanced Manufacturing Technology*, vol. 95, no. 1–4, pp. 527–550, Mar. 2018, doi: [10.1007/s00170-017-1172-6](https://doi.org/10.1007/s00170-017-1172-6).
- [20] G. C. Egan, A. J. Angilella, C. R. Corrado, and W. V. Skelton, “The impact of additive manufacturing induced geometric defects on auxetic lattices,” *Compos*

- Struct*, vol. 358, p. 118968, 2025, doi: <https://doi.org/10.1016/j.compstruct.2025.118968>.
- [21] A. Sola and A. Nouri, "Microstructural porosity in additive manufacturing: The formation and detection of pores in metal parts fabricated by powder bed fusion," *J Adv Manuf Process*, vol. 1, Jun. 2019, doi: 10.1002/amp2.10021.
- [22] W. Wang and S. Liang, "Prediction of molten pool height, contact angle, and balling occurrence in laser powder bed fusion," *The International Journal of Advanced Manufacturing Technology*, vol. 119, Apr. 2022, doi: 10.1007/s00170-021-08633-8.
- [23] S. Sui *et al.*, "Additive Manufacturing of Magnesium and its alloys: Process-Formability-Microstructure-Performance Relationship and Underlying Mechanism," *International Journal of Extreme Manufacturing*, vol. 5, p. 042009, Sep. 2023, doi: 10.1088/2631-7990/acf254.
- [24] K. Kempen, L. Thijs, B. Vrancken, S. Bols, J. Humbeeck, and J.-P. Kruth, "Producing crack-free, high density M2 HSS parts by Selective Laser Melting: Pre-heating the baseplate," *24th International SFF Symposium - An Additive Manufacturing Conference, SFF 2013*, Aug. 2013.
- [25] M. Grasso, V. Laguzza, Q. Semeraro, and B. M. Colosimo, "In-Process Monitoring of Selective Laser Melting: Spatial Detection of Defects Via Image Data Analysis," *J Manuf Sci Eng*, vol. 139, no. 5, p. 051001, 2016, doi: 10.1115/1.4034715.
- [26] M. Grasso, A. Remani, A. Dickins, B. Colosimo, and R. Leach, "In-situ measurement and monitoring methods for metal powder bed fusion: An updated review," *Meas Sci Technol*, vol. 32, Jul. 2021, doi: 10.1088/1361-6501/ac0b6b.
- [27] R. McCann *et al.*, "In-situ sensing, process monitoring and machine control in Laser Powder Bed Fusion: A review," *Addit Manuf*, vol. 45, p. 102058, 2021, doi: <https://doi.org/10.1016/j.addma.2021.102058>.
- [28] C. K. P. Vallabh and X. Zhao, "Melt pool temperature measurement and monitoring during laser powder bed fusion based additive manufacturing via single-camera two-wavelength imaging pyrometry (STWIP)," *J Manuf Process*, vol. 79, pp. 486–500, 2022, doi: <https://doi.org/10.1016/j.jmapro.2022.04.058>.
- [29] L. Mazzoleni, A. G. Demir, L. Caprio, M. Pacher, and B. Previtali, "Real-Time Observation of Melt Pool in Selective Laser Melting: Spatial, Temporal and Wavelength Resolution Criteria," *IEEE Trans Instrum Meas*, pp. 1–1, 2019, doi: 10.1109/tim.2019.2912236.
- [30] Y. Zhang *et al.*, "In-situ quality inspection based on coaxial melt pool images for laser powder bed fusion with depth graph network guided by prior knowledge,"

- Mech Syst Signal Process*, vol. 224, p. 111993, 2025, doi: <https://doi.org/10.1016/j.ymssp.2024.111993>.
- [31] A. Fernandez, R. Felice, C. A. Terrazas-Nájera, and R. Wicker, “Implications for accurate surface temperature monitoring in powder bed fusion: Using multi-wavelength pyrometry to characterize spectral emissivity during processing,” *Addit Manuf*, vol. 46, p. 102138, 2021, doi: <https://doi.org/10.1016/j.addma.2021.102138>.
- [32] T. Liu *et al.*, “In-situ infrared thermographic inspection for local powder layer thickness measurement in laser powder bed fusion,” *Addit Manuf*, vol. 55, p. 102873, 2022, doi: <https://doi.org/10.1016/j.addma.2022.102873>.
- [33] Z. Ren *et al.*, “Sub-millisecond keyhole pore detection in laser powder bed fusion using sound and light sensors and machine learning,” *Materials Futures*, vol. 3, no. 4, Dec. 2024, doi: 10.1088/2752-5724/ad89e2.
- [34] S. Sung, Y. Song, W. Kim, O. Kwon, and K.-Y. Jhang, “Comparison of melt pool dimension with in-situ monitored acoustic emission signal in laser powder bed fusion of austenitic stainless steel,” *Rapid Prototyp J*, vol. ahead-of-print, no. ahead-of-print, Jan. 2025, doi: 10.1108/RPJ-08-2024-0348.
- [35] P. J. DePond *et al.*, “In situ measurements of layer roughness during laser powder bed fusion additive manufacturing using low coherence scanning interferometry,” *Mater Des*, vol. 154, pp. 347–359, 2018, doi: <https://doi.org/10.1016/j.matdes.2018.05.050>.
- [36] N. Eschner, L. Weiser, B. Häfner, and G. Lanza, “Development of an Acoustic Process Monitoring System for Selective Laser Melting (SLM),” *Solid Freeform Fabrication Symposium*, no. Reschetnik 2017, pp. 2097–2117, 2018.
- [37] D. Ye, G. S. Hong, Y. Zhang, K. Zhu, and J. Y. H. Fuh, “Defect detection in selective laser melting technology by acoustic signals with deep belief networks,” *The International Journal of Advanced Manufacturing Technology*, vol. 96, no. 5, pp. 2791–2801, 2018, doi: 10.1007/s00170-018-1728-0.
- [38] J. R. Tempelman *et al.*, “Uncovering acoustic signatures of pore formation in laser powder bed fusion,” *The International Journal of Advanced Manufacturing Technology*, vol. 130, no. 5, pp. 3103–3114, 2024, doi: 10.1007/s00170-023-12771-6.
- [39] R. J. Smith, M. Hirsch, R. Patel, W. Li, A. T. Clare, and S. D. Sharples, “Spatially resolved acoustic spectroscopy for selective laser melting,” *J Mater Process Technol*, vol. 236, pp. 93–102, 2016, doi: 10.1016/j.jmatprotec.2016.05.005.
- [40] S. Clijsters, T. Craeghs, S. Buls, K. Kempen, and J.-P. Kruth, “In situ quality control of the selective laser melting process using a high-speed, real-time melt pool

- monitoring system,” *The International Journal of Advanced Manufacturing Technology*, vol. 75, no. 5, pp. 1089–1101, 2014, doi: 10.1007/s00170-014-6214-8.
- [41] P. Lott, H. Schleifenbaum, W. Meiners, K. Wissenbach, C. Hinke, and J. Bültmann, “Design of an optical system for the in situ process monitoring of Selective Laser Melting (SLM),” *Phys Procedia*, vol. 12, no. PART 1, pp. 683–690, 2011, doi: 10.1016/j.phpro.2011.03.085.
- [42] T. Kolb *et al.*, “Camera signal dependencies within coaxial melt pool monitoring in laser powder bed fusion,” *Rapid Prototyp J*, vol. ahead-of-print, Aug. 2019, doi: 10.1108/RPJ-01-2019-0022.
- [43] L. Scime and J. Beuth, “Using machine learning to identify in-situ melt pool signatures indicative of flaw formation in a laser powder bed fusion additive manufacturing process,” *Addit Manuf*, vol. 25, pp. 151–165, 2019, doi: <https://doi.org/10.1016/j.addma.2018.11.010>.
- [44] A. J. Dunbar and A. R. Nassar, “Assessment of optical emission analysis for in-process monitoring of powder bed fusion additive manufacturing,” *Virtual Phys Prototyp*, vol. 13, no. 1, pp. 14–19, Jan. 2018, doi: 10.1080/17452759.2017.1392683.
- [45] O. Ero, K. Taherkhani, and E. Toyserkani, “Optical tomography and machine learning for in-situ defects detection in laser powder bed fusion: A self-organizing map and U-Net based approach,” *Addit Manuf*, vol. 78, p. 103894, 2023, doi: <https://doi.org/10.1016/j.addma.2023.103894>.
- [46] M. Pavlov, M. Doubenskaia, and I. Smurov, “Pyrometric analysis of thermal processes in SLM technology,” *Phys Procedia*, vol. 5, no. PART 2, pp. 523–531, 2010, doi: 10.1016/j.phpro.2010.08.080.
- [47] S. Jayasinghe, P. Paoletti, C. Sutcliffe, J. Dardis, N. Jones, and P. L. Green, “Automatic quality assessments of laser powder bed fusion builds from photodiode sensor measurements,” *Progress in Additive Manufacturing*, vol. 7, no. 2, pp. 143–160, 2022, doi: 10.1007/s40964-021-00219-w.
- [48] D. Alberts, D. Schwarze, and G. Witt, “IN SITU MELT POOL MONITORING AND THE CORRELATION TO PART DENSITY OF INCONEL ® 718 FOR QUALITY ASSURANCE IN SELECTIVE LASER MELTING,” 2017 International Solid Freeform Fabrication Symposium, 2017.
- [49] T. Craeghs, S. Clijsters, J. P. Kruth, F. Bechmann, and M. C. Ebert, “Detection of Process Failures in Layerwise Laser Melting with Optical Process Monitoring,” in

- Physics Procedia*, Elsevier B.V., 2012, pp. 753–759. doi: 10.1016/j.phpro.2012.10.097.
- [50] V. Pandiyan, A. Baganis, R. Axel Richter, R. Wróbel, and C. Leinenbach, “Qualify-as-you-go: sensor fusion of optical and acoustic signatures with contrastive deep learning for multi-material composition monitoring in laser powder bed fusion process,” *Virtual Phys Prototyp*, vol. 19, no. 1, p. e2356080, Dec. 2024, doi: 10.1080/17452759.2024.2356080.
- [51] David Harvey, “<https://asdlb.org/imageandvideoexchangeforum/wavelength-selection-using-a-monochromator/>.”
- [52] Y. Kawahito, N. Matsumoto, M. Mizutani, and S. Katayama, “Characterisation of plasma induced during high power fibre laser welding of stainless steel,” *Science and Technology of Welding and Joining*, vol. 13, no. 8, pp. 744–748, Nov. 2008, doi: 10.1179/136217108X329313.
- [53] M. Collur and T. Debroy, “Emission spectroscopy of plasma during laser welding of AISI 201 stainless steel,” *Metallurgical transactions. B, Process metallurgy*, vol. 20, pp. 277–286, Apr. 1989, doi: 10.1007/BF02825608.
- [54] V. N. Lednev *et al.*, “Online and in situ laser-induced breakdown spectroscopy for laser welding monitoring,” *Spectrochim Acta Part B At Spectrosc*, vol. 175, p. 106032, 2021, doi: <https://doi.org/10.1016/j.sab.2020.106032>.
- [55] S. Kang, S. Jeon, K. Ryu, and J. Shin, “Online monitoring of weld cross-sectional shape using optical emission spectroscopy and neural network during laser dissimilar welding,” *Eng Appl Artif Intell*, vol. 141, p. 109847, 2025, doi: <https://doi.org/10.1016/j.engappai.2024.109847>.
- [56] L. Song and J. Mazumder, “Real Time Cr Measurement Using Optical Emission Spectroscopy During Direct Metal Deposition Process,” *IEEE Sens J*, vol. 12, no. 5, pp. 958–964, 2012, doi: 10.1109/JSEN.2011.2162316.
- [57] W. Ya, A. R. Konuk, R. Aarts, B. Pathiraj, and B. Huis in ‘t Veld, “Spectroscopic monitoring of metallic bonding in laser metal deposition,” *J Mater Process Technol*, vol. 220, pp. 276–284, 2015, doi: <https://doi.org/10.1016/j.jmatprotec.2015.01.026>.
- [58] A. R. Nassar, T. J. Spurgeon, and E. W. Reutzel, “Sensing defects during directed-energy additive manufacturing of metal parts using optical emissions spectroscopy,” 2015.
- [59] A. J. Dunbar, A. R. Nassar, E. W. Reutzel, and J. J. Blecher, “A real-time communication architecture for metal powder bed fusion additive manufacturing,” *Solid Freeform Fabrication 2016: Proceedings of the 27th Annual International*

Solid Freeform Fabrication Symposium - An Additive Manufacturing Conference, SFF 2016, pp. 67–80, 2016.

- [60] C. S. Lough *et al.*, “In-situ optical emission spectroscopy of selective laser melting,” *J Manuf Process*, vol. 53, pp. 336–341, 2020, doi: <https://doi.org/10.1016/j.jmapro.2020.02.016>.
- [61] M. Montazeri, R. Yavari, P. Rao, and P. Boulware, “In-Process Monitoring of Material Cross-Contamination Defects in Laser Powder Bed Fusion,” *J Manuf Sci Eng*, vol. 140, no. 11, 2018, doi: 10.1115/1.4040543.
- [62] C. Muhlroth and M. Grottke, “Artificial Intelligence in Innovation: How to Spot Emerging Trends and Technologies,” *IEEE Trans Eng Manag*, vol. 69, no. 2, pp. 493–510, 2022, doi: 10.1109/TEM.2020.2989214.
- [63] L. Meng *et al.*, “Machine Learning in Additive Manufacturing: A Review,” Jun. 01, 2020, *Springer*. doi: 10.1007/s11837-020-04155-y.
- [64] J. Qin *et al.*, “Research and application of machine learning for additive manufacturing,” Apr. 01, 2022, *Elsevier B.V.* doi: 10.1016/j.addma.2022.102691.
- [65] J. Kim, Z. Yang, H. Ko, H. Cho, and Y. Lu, “Deep learning-based data registration of melt-pool-monitoring images for laser powder bed fusion additive manufacturing,” *J Manuf Syst*, vol. 68, pp. 117–129, 2023, doi: <https://doi.org/10.1016/j.jmsy.2023.03.006>.
- [66] R. Drissi-Daoudi, G. Masinelli, C. de Formanoir, K. Wasmer, J. Jhabvala, and R. E. Logé, “Acoustic emission for the prediction of processing regimes in Laser Powder Bed Fusion, and the generation of processing maps,” *Addit Manuf*, vol. 67, p. 103484, 2023, doi: <https://doi.org/10.1016/j.addma.2023.103484>.
- [67] B. D. Bevans *et al.*, “In-Process Monitoring of Part Quality in Laser Powder Bed Fusion Additive Manufacturing Process Using Acoustic Emission Sensors,” *J Manuf Sci Eng*, vol. 147, no. 6, Mar. 2025, doi: 10.1115/1.4067848.
- [68] H. Baumgartl, J. Tomas, R. Buettner, and M. Merkel, “A deep learning-based model for defect detection in laser-powder bed fusion using in-situ thermographic monitoring,” *Progress in Additive Manufacturing*, vol. 5, no. 3, pp. 277–285, Sep. 2020, doi: 10.1007/s40964-019-00108-3.
- [69] E. Westphal and H. Seitz, “A machine learning method for defect detection and visualization in selective laser sintering based on convolutional neural networks,” *Addit Manuf*, vol. 41, p. 101965, 2021, doi: <https://doi.org/10.1016/j.addma.2021.101965>.

- [70] J. Li, L. Cao, J. Xu, S. Wang, and Q. Zhou, "In situ porosity intelligent classification of selective laser melting based on coaxial monitoring and image processing," *Measurement*, vol. 187, p. 110232, 2022, doi: <https://doi.org/10.1016/j.measurement.2021.110232>.
- [71] M. Bugatti and B. M. Colosimo, "Towards real-time in-situ monitoring of hot-spot defects in L-PBF: a new classification-based method for fast video-imaging data analysis," *J Intell Manuf*, vol. 33, no. 1, pp. 293–309, 2022, doi: 10.1007/s10845-021-01787-y.
- [72] M. Khanzadeh, S. Chowdhury, M. A. Tschopp, H. R. Doude, M. Marufuzzaman, and L. Bian, "In-situ monitoring of melt pool images for porosity prediction in directed energy deposition processes," *IISE Trans*, vol. 51, no. 5, pp. 437–455, May 2019, doi: 10.1080/24725854.2017.1417656.
- [73] K. Wasmer, T. Le-Quang, B. Meylan, and S. A. Shevchik, "In Situ Quality Monitoring in AM Using Acoustic Emission: A Reinforcement Learning Approach," *J Mater Eng Perform*, vol. 28, no. 2, pp. 666–672, 2019, doi: 10.1007/s11665-018-3690-2.
- [74] C. Knaak, L. Masseling, E. Duong, P. Abels, and A. Gillner, "Improving Build Quality in Laser Powder Bed Fusion Using High Dynamic Range Imaging and Model-Based Reinforcement Learning," *IEEE Access*, vol. 9, pp. 55214–55231, 2021, doi: 10.1109/ACCESS.2021.3067302.
- [75] E. Vasileska, A. Argilovski, M. Tomov, B. Jovanoski, and V. Gecevska, "Implementation of Machine Learning for Enhancing Lean Manufacturing Practices for Metal Additive Manufacturing," *IEEE Trans Eng Manag*, vol. 71, pp. 14836–14845, 2024, doi: 10.1109/TEM.2024.3459645.
- [76] G. Tapia, S. Khairallah, M. Matthews, W. E. King, and A. Elwany, "Gaussian process-based surrogate modeling framework for process planning in laser powder-bed fusion additive manufacturing of 316L stainless steel," *The International Journal of Advanced Manufacturing Technology*, vol. 94, no. 9, pp. 3591–3603, 2018, doi: 10.1007/s00170-017-1045-z.
- [77] C. Kamath, "Data mining and statistical inference in selective laser melting," *The International Journal of Advanced Manufacturing Technology*, vol. 86, no. 5, pp. 1659–1677, 2016, doi: 10.1007/s00170-015-8289-2.
- [78] L. Meng and J. Zhang, "Process Design of Laser Powder Bed Fusion of Stainless Steel Using a Gaussian Process-Based Machine Learning Model," *JOM*, vol. 72, no. 1, pp. 420–428, 2020, doi: 10.1007/s11837-019-03792-2.

- [79] C. Silbernagel, A. Aremu, and I. Ashcroft, “Using machine learning to aid in the parameter optimisation process for metal-based additive manufacturing,” *Rapid Prototyp J*, vol. 26, no. 4, pp. 625–637, Jan. 2020, doi: 10.1108/RPJ-08-2019-0213.
- [80] G. Tapia, A. H. Elwany, and H. Sang, “Prediction of porosity in metal-based additive manufacturing using spatial Gaussian process models,” *Addit Manuf*, vol. 12, pp. 282–290, Oct. 2016, doi: 10.1016/j.addma.2016.05.009.
- [81] H. Park, D. S. Nguyen, T. Le Hong, and X. Tran, “Machine learning-based optimization of process parameters in selective laser melting for biomedical applications,” *J Intell Manuf*, vol. 33, Aug. 2022, doi: 10.1007/s10845-021-01773-4.
- [82] A. Gaikwad, B. Giera, G. M. Guss, J. B. Forien, M. J. Matthews, and P. Rao, “Heterogeneous sensing and scientific machine learning for quality assurance in laser powder bed fusion – A single-track study,” *Addit Manuf*, vol. 36, Dec. 2020, doi: 10.1016/j.addma.2020.101659.
- [83] V. Mahato, M. A. Obeidi, D. Brabazon, and P. Cunningham, “Detecting voids in 3D printing using melt pool time series data,” *J Intell Manuf*, vol. 33, no. 3, pp. 845–852, Mar. 2022, doi: 10.1007/s10845-020-01694-8.
- [84] O. Kwon *et al.*, “A deep neural network for classification of melt-pool images in metal additive manufacturing,” *J Intell Manuf*, vol. 31, no. 2, pp. 375–386, Feb. 2020, doi: 10.1007/s10845-018-1451-6.
- [85] Y. Zhang, G. S. Hong, D. Ye, K. Zhu, and J. Y. H. Fuh, “Extraction and evaluation of melt pool, plume and spatter information for powder-bed fusion AM process monitoring,” *Mater Des*, vol. 156, pp. 458–469, Oct. 2018, doi: 10.1016/j.matdes.2018.07.002.
- [86] N. H. Paulson, B. Gould, S. J. Wolff, M. Stan, and A. Greco, “Correlations between thermal history and keyhole porosity in laser powder bed fusion,” *Addit Manuf*, vol. 34, no. 101213, 2020, doi: 10.1016/j.addma.2020.101213.
- [87] C. S. Lough *et al.*, “Correlation of SWIR imaging with LPBF 304L stainless steel part properties,” *Addit Manuf*, vol. 35, Oct. 2020, doi: 10.1016/j.addma.2020.101359.
- [88] J. Petrich, C. Gobert, S. Phoha, A. R. Nassar, and E. W. Reutzel, “MACHINE LEARNING FOR DEFECT DETECTION FOR PBFAM USING HIGH RESOLUTION LAYERWISE IMAGING COUPLED WITH POST-BUILD CT SCANS,” *Solid Freeform Fabrication 2017: Proceedings of the 28th Annual International*, 2017.

- [89] L. Scime and J. Beuth, “Anomaly detection and classification in a laser powder bed additive manufacturing process using a trained computer vision algorithm,” *Addit Manuf*, vol. 19, pp. 114–126, 2018, doi: <https://doi.org/10.1016/j.addma.2017.11.009>.
- [90] W. Zhang and P. Desai, *MACHINE LEARNING ENABLED POWDER SPREADING PROCESS MAP FOR METAL ADDITIVE MANUFACTURING (AM)*. 2017.
- [91] J. L. Bartlett, A. Jarama, J. Jones, and X. Li, “Prediction of microstructural defects in additive manufacturing from powder bed quality using digital image correlation,” *Materials Science and Engineering: A*, vol. 794, p. 140002, 2020, doi: <https://doi.org/10.1016/j.msea.2020.140002>.
- [92] S. Chowdhury, “Artificial Neural Network Based Geometric Compensation for Thermal Deformation in Additive Manufacturing Processes.”
- [93] X. Yao, S. K. Moon, and G. Bi, “A hybrid machine learning approach for additive manufacturing design feature recommendation,” *Rapid Prototyp J*, vol. 23, no. 6, pp. 983–997, Jan. 2017, doi: 10.1108/RPJ-03-2016-0041.
- [94] Z. Shen, X. Shang, M. Zhao, X. Dong, G. Xiong, and F.-Y. Wang, “A Learning-Based Framework for Error Compensation in 3D Printing,” *IEEE Trans Cybern*, vol. 49, no. 11, pp. 4042–4050, 2019, doi: 10.1109/TCYB.2019.2898553.
- [95] G. Williams, N. A. Meisel, T. W. Simpson, and C. McComb, “Design Repository Effectiveness for 3D Convolutional Neural Networks: Application to Additive Manufacturing,” *Journal of Mechanical Design*, vol. 141, no. 11, Sep. 2019, doi: 10.1115/1.4044199.
- [96] X. Zhang, X. Le, A. Panotopoulou, E. Whiting, and C. C. L. Wang, “Perceptual models of preference in 3D printing direction,” in *ACM Transactions on Graphics*, Association for Computing Machinery, Nov. 2015. doi: 10.1145/2816795.2818121.
- [97] Y. Shi, Y. Zhang, S. Baek, W. De Backer, and R. Harik, “Manufacturability analysis for additive manufacturing using a novel feature recognition technique,” *Comput Aided Des Appl*, vol. 15, no. 6, pp. 941–952, Nov. 2018, doi: 10.1080/16864360.2018.1462574.
- [98] Q. Li, I. Kucukkoc, and D. Z. Zhang, “Production planning in additive manufacturing and 3D printing,” *Comput Oper Res*, vol. 83, pp. 1339–1351, Jul. 2017, doi: 10.1016/j.cor.2017.01.013.
- [99] K. Ransikarbum, S. Ha, J. Ma, and N. Kim, “Multi-objective optimization analysis for part-to-Printer assignment in a network of 3D fused deposition modeling,” *J*

- Manuf Syst*, vol. 43, pp. 35–46, 2017, doi: <https://doi.org/10.1016/j.jmsy.2017.02.012>.
- [100] M. Fera, F. Fruggiero, A. Lambiase, R. Macchiaroli, and V. Todisco, “A modified genetic algorithm for time and cost optimization of an additive manufacturing single-machine scheduling,” *International Journal of Industrial Engineering Computations*, vol. 9, pp. 423–438, Oct. 2018, doi: 10.5267/j.ijiec.2018.1.001.
- [101] E. Vasileska, A. G. Demir, B. M. Colosimo, and B. Previtali, “A novel paradigm for feedback control in LPBF: layer-wise correction for overhang structures,” *Adv Manuf*, vol. 10, no. 2, pp. 326–344, 2022, doi: 10.1007/s40436-021-00379-6.
- [102] A. G. Demir, L. Mazzoleni, L. Caprio, M. Pacher, and B. Previtali, “Complementary use of pulsed and continuous wave emission modes to stabilize melt pool geometry in laser powder bed fusion,” *Opt Laser Technol*, vol. 113, no. October 2018, pp. 15–26, 2019, doi: 10.1016/j.optlastec.2018.12.005.
- [103] E. Onal, A. E. Medvedev, M. A. Leeﬂang, A. Molotnikov, and A. A. Zadpoor, “Novel microstructural features of selective laser melted lattice struts fabricated with single point exposure scanning,” *Addit Manuf*, vol. 29, p. 100785, 2019, doi: <https://doi.org/10.1016/j.addma.2019.100785>.
- [104] L. Caprio, F. Guaglione, and A. G. Demir, “Development of Single Point Exposure Strategy to Suppress Vapour Formation During the Laser Powder Bed Fusion of Zinc and Its Alloys BT - Selected Topics in Manufacturing: AITeM Young Researcher Award 2021,” L. Carrino and T. Tolio, Eds., Cham: Springer International Publishing, 2022, pp. 107–129. doi: 10.1007/978-3-030-82627-7_7.
- [105] F. Guaglione, L. Caprio, B. Previtali, and A. G. Demir, “Single point exposure LPBF for the production of biodegradable Zn-alloy lattice structures,” *Addit Manuf*, vol. 48, no. October, 2021, doi: 10.1016/j.addma.2021.102426.
- [106] Y. Li *et al.*, “Additively manufactured biodegradable porous zinc,” *Acta Biomater*, vol. 101, pp. 609–623, 2020, doi: <https://doi.org/10.1016/j.actbio.2019.10.034>.
- [107] Y. Qin *et al.*, “Additive manufacturing of biodegradable Zn-xWE43 porous scaffolds: Formation quality, microstructure and mechanical properties,” *Mater Des*, vol. 181, p. 107937, 2019, doi: <https://doi.org/10.1016/j.matdes.2019.107937>.
- [108] Y. Li *et al.*, “Corrosion fatigue behavior of additively manufactured biodegradable porous zinc,” *Acta Biomater*, vol. 106, pp. 439–449, 2020, doi: <https://doi.org/10.1016/j.actbio.2020.02.001>.
- [109] S. Ghouse, S. Babu, R. J. Van Arkel, K. Nai, P. A. Hooper, and J. R. T. Jeffers, “The influence of laser parameters and scanning strategies on the mechanical

- properties of a stochastic porous material,” *Mater Des*, vol. 131, pp. 498–508, 2017, doi: <https://doi.org/10.1016/j.matdes.2017.06.041>.
- [110] S. Tsopanos *et al.*, “The Influence of Processing Parameters on the Mechanical Properties of Selectively Laser Melted Stainless Steel Microlattice Structures,” *J Manuf Sci Eng*, vol. 132, no. 4, Jul. 2010, doi: 10.1115/1.4001743.
- [111] L. Mullen, R. C. Stamp, W. K. Brooks, E. Jones, and C. J. Sutcliffe, “Selective Laser Melting: A regular unit cell approach for the manufacture of porous, titanium, bone in-growth constructs, suitable for orthopedic applications,” *J Biomed Mater Res B Appl Biomater*, vol. 89B, no. 2, pp. 325–334, May 2009, doi: <https://doi.org/10.1002/jbm.b.31219>.
- [112] Y. Tian *et al.*, “Effect of Process and Geometric Parameters on Residual Distortion of Ti-6Al-4V Body-Centered Cubic Lattice Structures in Laser Powder Bed Fusion,” *Additive Manufacturing Frontiers*, vol. 3, no. 4, p. 200170, 2024, doi: <https://doi.org/10.1016/j.amf.2024.200170>.
- [113] B. Zluhan, S. Ramadurga Narasimharaju, A. Cholkar, K. Thomas, R. Raghavendra, and E. S. N. Lopes, “Design, defect analysis, compressive strength and surface texture characterization of Laser Powder Bed Fusion processed Ti6Al4V lattice structures,” *Journal of Materials Research and Technology*, vol. 35, pp. 2914–2933, Mar. 2025, doi: 10.1016/j.jmrt.2025.01.232.
- [114] C. Qiu *et al.*, “Influence of processing conditions on strut structure and compressive properties of cellular lattice structures fabricated by selective laser melting (vol 628, pg 188, 2015),” *Materials Science and Engineering A*, vol. 638, pp. 228–231, Jun. 2015, doi: 10.1016/j.msea.2015.04.074.
- [115] S. Yusuf and N. Gao, “Influence of energy density on metallurgy and properties in metal additive manufacturing,” *Materials Science and Technology*, vol. 33, pp. 1–21, Feb. 2017, doi: 10.1080/02670836.2017.1289444.
- [116] J. C. Griffis, K. Shahed, K. Meinert, B. Yilmaz, M. Lear, and G. Manogharan, “Multi-material laser powder bed fusion: effects of build orientation on defects, material structure and mechanical properties,” *npj Advanced Manufacturing*, vol. 2, no. 1, p. 5, 2025, doi: 10.1038/s44334-025-00020-5.
- [117] F. G. Fischer, M. G. Zimmermann, N. Praetzs, and C. Knaak, “Monitoring of the powder bed quality in metal additive manufacturing using deep transfer learning,” *Mater Des*, vol. 222, p. 111029, 2022, doi: <https://doi.org/10.1016/j.matdes.2022.111029>.
- [118] S. Qi *et al.*, “Effect of Powder Spreading Parameters on Laser Absorption Behavior and Processability of High-Strength Aluminum Alloy Fabricated by Laser Powder

- Bed Fusion,” *Adv Eng Mater*, vol. 26, no. 22, p. 2401588, Nov. 2024, doi: <https://doi.org/10.1002/adem.202401588>.
- [119] M. J. Matthews, G. Guss, S. A. Khairallah, A. M. Rubenchik, P. J. Depond, and W. E. King, “Denudation of metal powder layers in laser powder bed fusion processes,” *Acta Mater*, vol. 114, pp. 33–42, 2016, doi: <https://doi.org/10.1016/j.actamat.2016.05.017>.
- [120] S. A. Khairallah, A. T. Anderson, A. Rubenchik, and W. E. King, “Laser powder-bed fusion additive manufacturing: Physics of complex melt flow and formation mechanisms of pores, spatter, and denudation zones,” *Acta Mater*, vol. 108, pp. 36–45, 2016, doi: <https://doi.org/10.1016/j.actamat.2016.02.014>.
- [121] R. Drissi-Daoudi *et al.*, “Differentiation of materials and laser powder bed fusion processing regimes from airborne acoustic emission combined with machine learning,” *Virtual Phys Prototyp*, vol. 17, no. 2, pp. 181–204, Apr. 2022, doi: [10.1080/17452759.2022.2028380](https://doi.org/10.1080/17452759.2022.2028380).
- [122] B. N. Narayanan, K. Beigh, S. Duning, and D. Erdahl, “Automated material identification and segmentation using deep learning for laser powder bed fusion,” in *Proc.SPIE*, Aug. 2020, p. 115110P. doi: [10.1117/12.2567007](https://doi.org/10.1117/12.2567007).
- [123] E. Vasilevska, L. Caprio, A. G. Demir, and V. Gecevska, “Defect classification and dimensional estimation in single-point exposure laser powder bed fusion of lattice struts using optical emission spectroscopy,” *Progress in Additive Manufacturing*, pp. 1–17, Jun. 2025, doi: [10.1007/s40964-025-01184-4](https://doi.org/10.1007/s40964-025-01184-4).
- [124] W. Abd-Elaziem *et al.*, “On the current research progress of metallic materials fabricated by laser powder bed fusion process: a review,” *Journal of Materials Research and Technology*, vol. 20, pp. 681–707, 2022, doi: <https://doi.org/10.1016/j.jmrt.2022.07.085>.
- [125] L. H. Olivas-Alanis *et al.*, “Mechanical Properties of AISI 316L Lattice Structures via Laser Powder Bed Fusion as a Function of Unit Cell Features,” *Materials*, vol. 16, no. 3, Feb. 2023, doi: [10.3390/ma16031025](https://doi.org/10.3390/ma16031025).
- [126] T. C. Dzogbewu, “Laser powder bed fusion of Ti6Al4V lattice structures and their applications,” *Journal of Metals, Materials and Minerals*, vol. 30, no. 4, pp. 68–78, 2020, doi: [10.14456/jmmm.2020.53](https://doi.org/10.14456/jmmm.2020.53).
- [127] S. Stewart, “Spectral Peaks and Wien’s Displacement Law,” *J Thermophys Heat Trans*, vol. 26, pp. 689–692, Oct. 2012, doi: [10.2514/1.60241](https://doi.org/10.2514/1.60241).
- [128] J. A. Aguilera and C. Aragón, “Multi-element Saha–Boltzmann and Boltzmann plots in laser-induced plasmas,” *Spectrochim Acta Part B At Spectrosc*, vol. 62, no. 4, pp. 378–385, 2007, doi: <https://doi.org/10.1016/j.sab.2007.03.024>.

- [129] J. Peng, S. Peng, A. Jiang, J. Wei, C. Li, and J. Tan, “Asymmetric least squares for multiple spectra baseline correction,” *Anal Chim Acta*, vol. 683, no. 1, pp. 63–68, 2010, doi: <https://doi.org/10.1016/j.aca.2010.08.033>.
- [130] C. Tenbrock, T. Kelliger, N. Praetzsche, M. Ronge, L. Jauer, and J. H. Schleifenbaum, “Effect of laser-plume interaction on part quality in multi-scanner Laser Powder Bed Fusion,” *Addit Manuf*, vol. 38, Feb. 2021, doi: [10.1016/j.addma.2020.101810](https://doi.org/10.1016/j.addma.2020.101810).
- [131] Y. A. Mayi *et al.*, “Laser-induced plume investigated by finite element modelling and scaling of particle entrainment in laser powder bed fusion,” *J Phys D Appl Phys*, vol. 53, no. 7, 2020, doi: [10.1088/1361-6463/ab5900](https://doi.org/10.1088/1361-6463/ab5900).
- [132] S. Wold, K. Esbensen, and P. Geladi, “Principal component analysis,” *Chemometrics and Intelligent Laboratory Systems*, vol. 2, no. 1, pp. 37–52, 1987, doi: [https://doi.org/10.1016/0169-7439\(87\)80084-9](https://doi.org/10.1016/0169-7439(87)80084-9).
- [133] “NIST Atomic Spectra Database,” <https://www.nist.gov/pml/atomic-spectra-database>.
- [134] I. El Naqa and M. J. Murphy, “What Is Machine Learning?,” in *Machine Learning in Radiation Oncology: Theory and Applications*, I. El Naqa, R. Li, and M. J. Murphy, Eds., Cham: Springer International Publishing, 2015, pp. 3–11. doi: [10.1007/978-3-319-18305-3_1](https://doi.org/10.1007/978-3-319-18305-3_1).
- [135] S. Ray, “A Quick Review of Machine Learning Algorithms,” in *2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon)*, 2019, pp. 35–39. doi: [10.1109/COMITCon.2019.8862451](https://doi.org/10.1109/COMITCon.2019.8862451).
- [136] C. Kingsford and S. L. Salzberg, “What are decision trees?,” *Nat Biotechnol*, vol. 26, no. 9, pp. 1011–1013, 2008, doi: [10.1038/nbt0908-1011](https://doi.org/10.1038/nbt0908-1011).
- [137] M. Galar, A. Fernandez, E. Barrenechea, H. Bustince, and F. Herrera, “A Review on Ensembles for the Class Imbalance Problem: Bagging-, Boosting-, and Hybrid-Based Approaches,” *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 42, no. 4, pp. 463–484, 2012, doi: [10.1109/TSMCC.2011.2161285](https://doi.org/10.1109/TSMCC.2011.2161285).
- [138] A. J. Ferreira and M. A. T. Figueiredo, “Boosting Algorithms: A Review of Methods, Theory, and Applications,” in *Ensemble Machine Learning: Methods and Applications*, C. Zhang and Y. Ma, Eds., New York, NY: Springer New York, 2012, pp. 35–85. doi: [10.1007/978-1-4419-9326-7_2](https://doi.org/10.1007/978-1-4419-9326-7_2).
- [139] G. Ngo, R. Beard, and R. Chandra, “Evolutionary bagging for ensemble learning,” *Neurocomputing*, vol. 510, pp. 1–14, 2022, doi: <https://doi.org/10.1016/j.neucom.2022.08.055>.

- [140] S. Dinakaran and P. R. J. Thangaiah, "Ensemble Method of Effective AdaBoost Algorithm for Decision Tree Classifiers," *International Journal on Artificial Intelligence Tools*, vol. 26, no. 03, p. 1750007, Dec. 2016, doi: 10.1142/S0218213017500075.
- [141] Y. Freund and R. E. Schapire, "Experiments with a New Boosting Algorithm," in *International Conference on Machine Learning*, 1996. [Online]. Available: <https://api.semanticscholar.org/CorpusID:1836349>
- [142] F.-J. Yang, "An Implementation of Naive Bayes Classifier," in *2018 International Conference on Computational Science and Computational Intelligence (CSCI)*, 2018, pp. 301–306. doi: 10.1109/CSCI46756.2018.00065.
- [143] H. Kamel, D. Abdulah, and J. M. Al-Tuwaijari, "Cancer Classification Using Gaussian Naive Bayes Algorithm," in *2019 International Engineering Conference (IEC)*, 2019, pp. 165–170. doi: 10.1109/IEC47844.2019.8950650.
- [144] G. Guo, H. Wang, D. Bell, Y. Bi, and K. Greer, "KNN Model-Based Approach in Classification," in *On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE*, R. Meersman, Z. Tari, and D. C. Schmidt, Eds., Berlin, Heidelberg: Springer Berlin Heidelberg, 2003, pp. 986–996.
- [145] L. Peterson, "K-nearest neighbor," *Scholarpedia*, vol. 4, no. 2, p. 1883, 2009, doi: 10.4249/scholarpedia.1883.
- [146] S. Zhang, "Challenges in KNN Classification," *IEEE Trans Knowl Data Eng*, vol. 34, no. 10, pp. 4663–4675, 2022, doi: 10.1109/TKDE.2021.3049250.
- [147] W. S. Noble, "What is a support vector machine?," *Nat Biotechnol*, vol. 24, no. 12, pp. 1565–1567, 2006, doi: 10.1038/nbt1206-1565.
- [148] Y. Hamasuna, Y. Endo, and S. Miyamoto, "Support Vector Machine for data with tolerance based on Hard-margin and Soft-Margin," in *2008 IEEE International Conference on Fuzzy Systems (IEEE World Congress on Computational Intelligence)*, 2008, pp. 750–755. doi: 10.1109/FUZZY.2008.4630454.
- [149] T. Eitrich and B. Lang, "Efficient optimization of support vector machine learning parameters for unbalanced datasets," *J Comput Appl Math*, vol. 196, no. 2, pp. 425–436, 2006, doi: <https://doi.org/10.1016/j.cam.2005.09.009>.
- [150] O. L. Mangasarian and D. R. Musicant, "Lagrangian Support Vector Machines," *Journal of Machine Learning Research*, vol. 1, pp. 161–177, 2001.
- [151] A. Tharwat, "Parameter investigation of support vector machine classifier with kernel functions," *Knowl Inf Syst*, vol. 61, no. 3, pp. 1269–1302, 2019, doi: 10.1007/s10115-019-01335-4.

- [152] Mehmet Ali TOR, “<https://medium.com/@mehmetalitor/support-vector-machine-and-kernel-trick-45b122edc773>.”
- [153] E. Schulz, M. Speekenbrink, and A. Krause, “A tutorial on Gaussian process regression: Modelling, exploring, and exploiting functions,” *J Math Psychol*, vol. 85, pp. 1–16, 2018, doi: <https://doi.org/10.1016/j.jmp.2018.03.001>.
- [154] Y. Pan, X. Zeng, H. Xu, Y. Sun, D. Wang, and J. Wu, “Evaluation of Gaussian process regression kernel functions for improving groundwater prediction,” *J Hydrol (Amst)*, vol. 603, p. 126960, 2021, doi: <https://doi.org/10.1016/j.jhydrol.2021.126960>.
- [155] A. J. Smola and B. Schölkopf, “A tutorial on support vector regression,” *Stat Comput*, vol. 14, no. 3, pp. 199–222, 2004, doi: 10.1023/B:STCO.0000035301.49549.88.
- [156] J. Friedman, “Greedy Function Approximation: A Gradient Boosting Machine,” *The Annals of Statistics*, vol. 29, Nov. 2000, doi: 10.1214/aos/1013203451.
- [157] M. S. Alajmi and A. M. Almeshal, “Least squares boosting ensemble and quantum-behaved particle swarm optimization for predicting the surface roughness in face milling process of aluminum material,” *Applied Sciences (Switzerland)*, vol. 11, no. 5, pp. 1–13, Mar. 2021, doi: 10.3390/app11052126.
- [158] J. Mendes-Moreira, C. Soares, A. M. Jorge, and J. F. De Sousa, “Ensemble approaches for regression: A survey,” *ACM Comput. Surv.*, vol. 45, no. 1, Dec. 2012, doi: 10.1145/2379776.2379786.
- [159] J. Zou, Y. Han, and S.-S. So, “Overview of Artificial Neural Networks,” in *Artificial Neural Networks: Methods and Applications*, D. J. Livingstone, Ed., Totowa, NJ: Humana Press, 2009, pp. 14–22. doi: 10.1007/978-1-60327-101-1_2.
- [160] F. Shao and Z. Shen, “How can artificial neural networks approximate the brain?,” Jan. 09, 2023, *Frontiers Media S.A.* doi: 10.3389/fpsyg.2022.970214.
- [161] A. D. Rasamoelina, F. Adjailia, and P. Sinčák, “A Review of Activation Function for Artificial Neural Network,” in *2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, 2020, pp. 281–286. doi: 10.1109/SAMI48414.2020.9108717.
- [162] J. Li, J. Cheng, J. Shi, and F. Huang, “Brief Introduction of Back Propagation (BP) Neural Network Algorithm and Its Improvement,” in *Advances in Computer Science and Information Engineering*, D. Jin and S. Lin, Eds., Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, pp. 553–558.

- [163] M. Ringnér, “What is principal component analysis?,” *Nat Biotechnol*, vol. 26, no. 3, pp. 303–304, 2008, doi: 10.1038/nbt0308-303.
- [164] A. Svidzinsky *et al.*, “Bohr model and dimensional scaling analysis of atoms and molecules,” *Int Rev Phys Chem*, vol. 27, no. 4, pp. 665–723, Oct. 2008, doi: 10.1080/01442350802364664.
- [165] J. C. Tully, “Molecular dynamics with electronic transitions,” *J Chem Phys*, vol. 93, no. 2, pp. 1061–1071, Jul. 1990, doi: 10.1063/1.459170.
- [166] M. O. Scully and M. Sargent, “The concept of the photon,” *Phys Today*, vol. 25, no. 3, pp. 38–47, Mar. 1972, doi: 10.1063/1.3070771.
- [167] H. MARGENAU and M. LEWIS, “Structure of Spectral Lines from Plasmas,” *Rev Mod Phys*, vol. 31, no. 3, pp. 569–615, Jul. 1959, doi: 10.1103/RevModPhys.31.569.
- [168] C. Aragón and J. A. Aguilera, “Characterization of laser induced plasmas by optical emission spectroscopy: A review of experiments and methods,” *Spectrochim Acta Part B At Spectrosc*, vol. 63, no. 9, pp. 893–916, 2008, doi: <https://doi.org/10.1016/j.sab.2008.05.010>.
- [169] B. R. Mollow, “Absorption and Emission Line-Shape Functions for Driven Atoms,” *Phys Rev A (Coll Park)*, vol. 5, no. 3, pp. 1522–1527, Mar. 1972, doi: 10.1103/PhysRevA.5.1522.
- [170] M. Ozawa, “Heisenberg’s original derivation of the uncertainty principle and its universally valid reformulations,” *Curr Sci*, vol. 109, no. 11, pp. 2006–2016, 2015, [Online]. Available: <http://www.jstor.org/stable/24906690>
- [171] A. C. Kolb and H. Griem, “Theory of Line Broadening in Multiplet Spectra,” *Physical Review*, vol. 111, no. 2, pp. 514–521, Jul. 1958, doi: 10.1103/PhysRev.111.514.
- [172] L. M. Biberman and G. É. Norman, “CONTINUOUS SPECTRA OF ATOMIC GASES AND PLASMA,” *Soviet Physics Uspekhi*, vol. 10, no. 1, p. 52, 1967, doi: 10.1070/PU1967v010n01ABEH003199.
- [173] G. S. Ranganath, “Black-body radiation,” *Resonance*, vol. 13, no. 2, pp. 115–133, 2008, doi: 10.1007/s12045-008-0028-7.
- [174] O. Passon and J. Grebe-Ellis, “Planck’s radiation law, the light quantum, and the prehistory of indistinguishability in the teaching of quantum mechanics,” *Eur J Phys*, vol. 38, no. 3, p. 035404, 2017, doi: 10.1088/1361-6404/aa6134.
- [175] R. Siegel and J. R. Howell, “Thermal radiation heat transfer: Radiation Transfer With Absorbing, Emitting, and Scattering Media.”

- [176] S. M. Stewart, “Spectral Peaks and Wien’s Displacement Law,” *J Thermophys Heat Trans*, vol. 26, no. 4, pp. 689–692, Oct. 2012, doi: 10.2514/1.T3789.
- [177] Dave Dunbar, “<http://pyweb.swan.ac.uk/~dunbar/PH104/lec11/lecture.html>.”
- [178] B. Das, “Obtaining Wien’s displacement law from Planck’s law of radiation,” *Phys Teach*, vol. 40, no. 3, pp. 148–149, Mar. 2002, doi: 10.1119/1.1466547.
- [179] J. Thouin, M. Benmouffok, P. Freton, and J. J. Gonzalez, “Interpretation of temperature measurements by the Boltzmann plot method on spatially integrated plasma oxygen spectral lines,” *EPJ Applied Physics*, vol. 98, 2023, doi: 10.1051/epjap/2023230072.
- [180] S. N. T. AlRashid, N. F. Majeed, M. A. Azeez, and S. N. Mazhir, “Calculating plasma parameters for Zn target using laser-induced breakdown spectroscopy,” *Journal of Optics*, 2025, doi: 10.1007/s12596-025-02644-4.
- [181] B. Bousquet, V. Gardette, V. M. Ros, R. Gaudio, M. Dell’Aglia, and A. De Giacomo, “Plasma excitation temperature obtained with Boltzmann plot method: Significance, precision, trueness and accuracy,” *Spectrochim Acta Part B At Spectrosc*, vol. 204, p. 106686, 2023, doi: <https://doi.org/10.1016/j.sab.2023.106686>.
- [182] J. A. Aguilera and C. Aragón, “Multi-element Saha–Boltzmann and Boltzmann plots in laser-induced plasmas,” *Spectrochim Acta Part B At Spectrosc*, vol. 62, no. 4, pp. 378–385, 2007, doi: <https://doi.org/10.1016/j.sab.2007.03.024>.
- [183] A. Mostafaei *et al.*, “Defects and anomalies in powder bed fusion metal additive manufacturing,” *Curr Opin Solid State Mater Sci*, vol. 26, no. 2, p. 100974, 2022, doi: <https://doi.org/10.1016/j.cossms.2021.100974>.
- [184] L. Caprio, A. G. Demir, and B. Previtali, “External Illumination Enables Coaxial Sensing of Surface and Subsurface Molten Pool Geometry in LPBF,” *Metals (Basel)*, vol. 12, no. 10, Oct. 2022, doi: 10.3390/met12101762.
- [185] F. Guaglione, L. Caprio, B. Previtali, and A. G. Demir, “Single point exposure LPBF for the production of biodegradable Zn-alloy lattice structures,” *Addit Manuf*, vol. 48, no. October, 2021, doi: 10.1016/j.addma.2021.102426.
- [186] E. Vasileska, A. G. Demir, B. Colosimob, V. Gecevska, and B. Previtali, “Energy input adaptation according to part geometry in selective laser melting through empirical modelling of thermal emission,” *Advanced Technologies & Materials*, vol. 47, pp. 11–17, Jun. 2022, doi: 10.24867/ATM-2022-1-003.
- [187] L. Riva, P. S. Ginestra, and E. Ceretti, “Mechanical characterization and properties of laser-based powder bed-fused lattice structures: a review,” *The International*

- Journal of Advanced Manufacturing Technology*, vol. 113, pp. 649–671, 2021, doi: 10.1007/s00170-021-06631-4/Published.
- [188] L. Støhle and S. Wold, “Analysis of variance (ANOVA),” *Chemometrics and Intelligent Laboratory Systems*, vol. 6, no. 4, pp. 259–272, 1989, doi: [https://doi.org/10.1016/0169-7439\(89\)80095-4](https://doi.org/10.1016/0169-7439(89)80095-4).
- [189] T.-T. Wong and P.-Y. Yeh, “Reliable Accuracy Estimates from k-Fold Cross Validation,” *IEEE Trans Knowl Data Eng*, vol. 32, no. 8, pp. 1586–1594, 2020, doi: 10.1109/TKDE.2019.2912815.
- [190] L. Yang and A. Shami, “On hyperparameter optimization of machine learning algorithms: Theory and practice,” *Neurocomputing*, vol. 415, pp. 295–316, 2020, doi: <https://doi.org/10.1016/j.neucom.2020.07.061>.
- [191] J. Wu, X.-Y. Chen, H. Zhang, L.-D. Xiong, H. Lei, and S.-H. Deng, “Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization,” *Journal of Electronic Science and Technology*, vol. 17, no. 1, pp. 26–40, 2019, doi: <https://doi.org/10.11989/JEST.1674-862X.80904120>.
- [192] A. H. Victoria and G. Maragatham, “Automatic tuning of hyperparameters using Bayesian optimization,” *Evolving Systems*, vol. 12, no. 1, pp. 217–223, 2021, doi: 10.1007/s12530-020-09345-2.
- [193] I. S. Al-Mejibli, J. K. Alwan, and D. H. Abd, “The effect of gamma value on support vector machine performance with different kernels,” *International Journal of Electrical and Computer Engineering*, vol. 10, no. 5, pp. 5497–5506, Oct. 2020, doi: 10.11591/IJECE.V10I5.PP5497-5506.
- [194] R. Halder, M. Uddin, M. A. Uddin, S. Aryal, and A. Khraisat, “Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications,” *J Big Data*, vol. 11, Aug. 2024, doi: 10.1186/s40537-024-00973-y.
- [195] D. C. Liu and J. Nocedal, “On the limited memory BFGS method for large scale optimization,” *Math Program*, vol. 45, no. 1, pp. 503–528, 1989, doi: 10.1007/BF01589116.
- [196] E. Schulz, M. Speekenbrink, and A. Krause, “A tutorial on Gaussian process regression: Modelling, exploring, and exploiting functions,” *J Math Psychol*, vol. 85, pp. 1–16, 2018, doi: <https://doi.org/10.1016/j.jmp.2018.03.001>.
- [197] D. W. Ball, *Field Guide to Spectroscopy*, Vol. FG08. SPIE, 2006. [Online]. Available: <https://api.semanticscholar.org/CorpusID:118576773>
- [198] P. Eilers and H. Boelens, “Baseline Correction with Asymmetric Least Squares Smoothing,” *Leiden University Medical Centre Report 1*, vol. 5, Nov. 2005.

- [199] S. G. Rautian and I. I. Sobel'man, "The effects of collisions on the Doppler broadening of spectral lines," *Soviet Physics Uspekhi*, vol. 9, number 5, pp. 209–236, 1966.
- [200] H. R. Griem, "Stark Broadening of Isolated Spectral Lines from Heavy Elements in a Plasma," *Physical Review*, vol. 128, no. 2, pp. 515–523, Oct. 1962, doi: 10.1103/PhysRev.128.515.
- [201] R. D. Cowan and G. H. Dieke, "Self-Absorption of Spectrum Lines," *Rev Mod Phys*, vol. 20, no. 2, pp. 418–455, Apr. 1948, doi: 10.1103/RevModPhys.20.418.