Sachbericht zum Verwendungsnachweis

Teilvorhaben *Fraunhofer IAPT*

Anschrift und Kontakt:
Fraunhofer IAPT
Am Schleusengraben 14
21029 Hamburg

Projektleiter

Stefan Grottker
stefan.grottker@iapt.fraunhofer.de
T +49 40 484010-763

Verbundvorhaben: *AMalytik – Ausschussreduktion durch die KI-basierte Analyse qualitätsrelevanter Daten für eine umweltfreundliche und ressourceneffiziente additive Produktion von sicherheitsrelevanten Luftfahrtbauteilen*

Förderkennzeichen: *20D2124D*

Laufzeit des Vorhabens: *01.01.2023 – 31.12.2025*

Teil II: Eingehende Darstellung

1. Durchgeführte Arbeiten im Kontext der Arbeitspakete aus der Vorhabenbeschreibung

Im Folgenden werden die durchgeführten Arbeiten im Kontext der ursprünglichen Vorhabensbeschreibung ausführlicher dargestellt. Hierfür wird spezifisch auf die Inhalte der Arbeitspakete eingegangen

AP1.1 Ermittlung der bekannten CTQs und möglicher Einflussgrößen für die betrachtete AM Prozesskette

Das Kernziel dieses AP ist es, daten- und algorithmenbasierte Qualitätsanalysen zu entwickeln, um kritische Einflussgrößen auf spezifizierte Qualitätskennwerte zu identifizieren, zu kontrollieren und zu optimieren. Der entscheidende erste Schritt hierfür war/ist die Ermittlung der im AMalytik-Projekt relevanten und kritischen Qualitätsmerkmale (CTQ, engl. „critical to quality“), anhand derer die Einflussfaktoren und ihre Wirkungsweise untersucht werden.

Das IAPT hat im Rahmen des Projektantrags von AMalytik (siehe Teilvorhabenbeschreibung IAPT, Tabelle 3) eine grundlegende Vorauswahl möglicher CTQs zusammengestellt. Diese Liste wurde als Basis herangezogen. Toolcraft hat diese Auswahl anhand ihrer Erfahrungen in Zusammenarbeit mit Industriepartnern – insbesondere aus der Luftfahrtbranche – verfeinert und komplementiert. Die resultierenden Einschätzungen und Bewertungen können seitens IAPT, welches ebenso viel Erfahrung in dem Bereich Luftfahrt hat, bestätigt und unterstützt werden. Insgesamt konnte die Liste durch dieses Vorgehen bereits auf die wesentlichen Faktoren in Hinblick auf die qualitätsrelevanten Messgrößen für AMalytik reduziert werden. Das Ergebnis ist in der folgenden Tabelle dargestellt.

CTQ	Messverfahren Toolcraft AMalytik	Kategorie
Streckgrenze	**Bestimmung nach ISO 6892-1a**	**Mechanische Eigenschaften**
Zugfestigkeit	**Bestimmung nach ISO 6892-1a**	
E-Modul	**Bestimmung nach ISO 6892-1a**	
Bruchdehnung	**Bestimmung nach ISO 6892-1a**	
Dichte	**Schliffbilder nach ASTM E3**	**Strukturelle Bauteileigenschaften**
Porenverteilung und -größe	**Schliffbilder nach ASTM E3**	
Risse	**Schliffbilder nach ASTM E3**	
(Oberflächenrauheit	**Laserscanningmikroskopie, Perthometrie**	**Oberflächenbeschaffenheit)**

Ein zusätzlicher optionaler Austausch mit den assoziierten Partnern war für das Projekttreffen am 12. Oktober 2023 am WZL an der RWTH Aachen angedacht. Da die Partner an dem

Treffen nicht teilgenommen haben, hat dies nicht stattgefunden. Stattdessen beabsichtigen wir, die finale Auswahl mit den assoziierten Partnern gemeinsam mit der Liste an Einflussfaktoren in 2024 zu teilen.

CTPs und Prozesskette (L-PBF) – bekannte Einflussgrößen

Die spezifizierten CTQs werden durch eine Vielfalt an Einflüssen in der Erstellung eines Bauteils beeinflusst, d. h. entlang der gesamten Prozesskette, beginnend mit dem Bauteil- und Baujob-Design bis hin zu Prüfverfahren in der Qualitätssicherung zum Abschluss der Fertigung. Hierunter fallen insbesondere bereits bekannte kritische Einflussfaktoren auf den Fertigungsprozess (CTPs, engl. „critical to process“) und somit der Qualität des Bauteils. Hierbei ist die Wahl der Fertigungstechnologie entscheidend in Hinblick auf die notwendigen Prozessschritte und damit verbundenen Einflussfaktoren. Im Rahmen von AMalytik fokussieren wir uns auf das selektive Laserstrahlschmelzen (L-PBF, engl. laser powder bed fusion), welches ein etabliertes Verfahren im Luftfahrtsektor ist (Munsch et al., 2023).

Anhand von Normen wie der DIN EN ISO/ASTM 52920 (DIN Deutsches Institut für Normung e. V., 2023) und ECSS-Q-ST-70-80C (European Cooperation for Space Standardization, 2021) sowie der vorliegenden Prozesskette wurden sowohl am IAPT als auch bei Toolcraft zunächst diese bekannten prozesskritischen Einflussgrößen ermittelt. Die tatsächliche Intensität des jeweiligen Einflusses kann nicht verallgemeinert zusammengefasst werden; dies hängt maßgeblich von den weiteren Faktoren im Prozess und konkreten Versuchsaufbauten ab. Beispiele für bekannte CTPs sind:

Wahl der Prozessparameter (Ausschnitt):

- Laserleistung
- Schichtstärke
- Scangeschwindigkeit
- Hatch-Abstand
- Bauplattformtemperatur
- Inertgas-Geschwindigkeit
- Baujobdesign: z. B. Bauteilpositionierung, Bauteilausrichtung
- Umgebungsbedingungen: z. B. Luftfeuchtigkeit, Temperaturen
- Ausgangsmaterialien, insb. Pulvereigenschaften: z. B. Partikelgrößenverteilung

Darüber hinaus ist ein Ziel des Projekts, weitere mögliche Einflussfaktoren entlang der Prozesskette zu identifizieren. Zu diesem Zweck wurden wissenschaftliche Vorarbeiten des IAPT zusammengetragen, Expert:innen-Interviews und Workshops am IAPT und bei Toolcraft durchgeführt. Ausführliche wissenschaftliche Arbeiten beschreiben das Fertigungsverfahren und die Prozesskette des L-PBF-Prozesses und benennen Einflüsse entlang dieser (Rehme, 2010) (Lafrentz, 2018). Diese Ausarbeitungen wurden zusammengetragen und mit Projektergebnissen aus vorangegangenen, teils spezialisierten Projekten kombiniert.

Als pulverbettbasiertes Verfahren spielt im L-PBF-Prozess das Ausgangsmaterial – das Pulver – in Form seiner Eigenschaften und Charakteristika eine entscheidende Rolle. Das Projekt qualiTi [IGF-Vorhaben Nr: 19204 BG] hat hierzu erste Untersuchungen gemacht, die in Folgeprojekten wie PERU [FKZ: 03LB5007B] am IAPT fortgesetzt werden. Insofern besteht hierzu großes Wissen am Institut. Gleichwohl konnte etwa durch Industrieprojekte Expertise im Bereich des Designs und der Fertigungsvorbereitung aufgebaut werden und somit als Fachwissen in die Sammlung und das Clustering der Einflussfaktoren am Institut einfließen. Dies wurde zum einen anhand der Projektdokumentationen, zum anderen anhand von Befragungen von einzelnen Expert:innen aus dem wissenschaftlichen sowie technischen Bereich und Workshops umgesetzt.

Die zusammengetragene Liste wurde auf AMalytik zugeschnitten und im Anschluss Toolcraft zur Verfügung gestellt. Das dortige Fachpersonal hat die Liste entsprechend angepasst und ergänzt, so dass der Prozess für AMalytik bei Toolcraft abgebildet wird. Darüber hinaus wurde eine Priorisierung der möglichen Einflussgrößen vorgenommen, wobei die Zahl eins eine geringe Priorität und fünf eine hohe Priorität darstellt. Hierbei ist zu betonen, dass es sich um eine explizite Abschätzung in Bezug auf AMalytik handelt. Größen, für die keine Veränderungen in Betracht gezogen und entsprechend aufgenommen werden, haben folglich eine geringere Relevanz als sich verändernde Faktoren. Dies ist wichtig zu beachten, da für AMalytik bspw. mit einem einheitlichen Material auf derselben Anlage gefertigt wird. Insofern werden bspw. keine Schlussfolgerungen über den Einfluss der Anlage X im Vergleich zu Anlage Z (bei Toolcraft) auf den Prozess und die entstehende Qualität gezogen werden können.

Die resultierende Klassifizierung kann einerseits für eine Priorisierung der Faktoren in Bezug auf die Dokumentation sowie Digitalisierung und Automatisierung genutzt werden. Für eine effiziente Ressourcennutzung ist dies entscheidend, da es etwa bei der Einschätzung von Dringlichkeiten und der Erstellung von Digitalisierungsabfolgen unterstützt. Andererseits erhalten wir durch die Einschätzungen praktische Erfahrungswerte, welche Parameter besonders interessant sein können in der anschließenden Analyse. Gleichwohl wird es interessant sein zu sehen, wie gut die Abschätzungen zu den Analyseergebnissen in Bezug auf Einflussfaktoren und ihrer Relevanz passen und an welchen Stellen es Differenzen geben wird.

Um ein möglichst umfassendes Bild der Priorisierung zu erhalten, wird GE Additive die Liste an Einflussfaktoren analog zu Toolcraft bewerten. GE Additive arbeitet mit anderen Fertigungsanlagen als Toolcraft und der Prozess selbst ist ebenso unterschiedlich. Aufgrund dessen sind Anpassungen und andere Priorisierungen zu erwarten, deren Auswertung eine interessante Aufgabe darstellen kann. Zur Wahrung der Unvoreingenommenheit wird GE Additive die Liste ohne die Bewertung seitens Toolcraft übermittelt.

Auf Grund der Gesamtverzögerung in diesem Arbeitspaket wird GE Additive die Liste zu Beginn von 2024 erhalten und entsprechend die Bewertung vornehmen. Die finale Version der Liste an Einflussfaktoren (welche Meilenstein 1.1 entspricht) inklusive der Priorisierung von Toolcraft ist in Tabelle A.1.1 im Anhang zu finden. Wenn die Bewertung seitens GE Additive vorliegt, sollen die Listen zusammengeführt und mit den assoziierten Partnern – zusammen mit den CTQs – geteilt werden.

Die Verzögerungen in diesem Arbeitspaket sind unter anderem dadurch entstanden, dass beide Projektbearbeitenden bzw. -leitenden erst mit Start des Projekts (bzw. danach) Teil des jeweiligen Teams wurden. Insofern bestand kein Vorwissen aus der Antragserstellung. Zudem hatten beide wenig Vorerfahrung mit den Prozessen des L-PBF-Prozesses.

Außerdem wurde die Chance ergriffen, eine sehr ausführliche Liste aufzustellen. Motivation hier ist, das grundsätzliche Risiko einer unvollständigen oder fehlerhaften Angabe von Einflussgrößen zu vermindern. Fehlende Variablen in einer Analyse beeinflussen das Ergebnis indirekt und stellen somit eine Größe mit unbekannten Auswirkungen in einem Modell dar. Da parallel jedoch die Notwendigkeit der Fokussierung besteht und nicht alle möglichen Größen digitalisiert werden können, besteht weiterhin das Risiko, nicht alle relevanten Variablen in die Datenbank und somit Analysen aufnehmen zu können.

Im Zuge der Bewertung möglicher Einflussfaktoren wurde seitens Toolcraft eine vorab Einschätzung vorgenommen, welche Daten im Konsortium teilbar sind. Derzeit hat sich herausgestellt, dass Ergebnisse aus Pulveranalysen, d. h. Charakteristika des Pulvers wie etwa Partikelgrößenverteilung, nicht unvoreingenommen weitergegeben werden dürfen. Ausschlaggebend hierfür ist, dass die Identifizierung und entsprechende Steuerung der optimalen Pulvereigenschaften maßgeblich zu der hohen Bauteilqualität Toolcrafts beiträgt und somit einem Kernelement des Geschäftserfolgs (und -geheimnisses) ist. Insofern sind Pulvereigenschaften aus der Liste an Einflussfaktoren weitgehendst entfernt worden. Dies ist bei der Planung, Erstellung und Durchführung von Analysen zu berücksichtigen. Das Konsortium und speziell das IAPT wird diese Entscheidung als Chance für das Projekt sehen, indem wir uns auf die Analyse anderer Einflüsse fokussieren.

Ergänzende wissenschaftliche Arbeit 2024: FMEA-basierte CTP-Erweiterungen

Im Rahmen einer im Jahr 2024 durchgeführten wissenschaftlichen Arbeit konnten weitere Prozesseinflussgrößen ermittelt werden. In dieser wissenschaftlichen Arbeit lag der Fokus

zum einen auf der Validierung der bisherigen Erkenntnisse durch umfassende Literaturrecherchen und zum anderen auf noch nicht explizit erörterte Einflussgrößen. Insbesondere der zweite Teil der Arbeit liefert auch für AMalytik wertvolle Erkenntnisse. Die Ermittlung der neuen CTPs erfolgte durch umfangreiche Fehlermöglichkeits- und Einflussanalysen (FMEA) gemeinsam mit technischem und wissenschaftlichem Personal am Fraunhofer IAPT. Es stellte sich heraus, dass besonders die Perspektive der Techniker Erkenntnisse über Wirkzusammenhänge liefert, die mit Literaturrecherchen nicht oder nur sehr schwer zu bestimmen ist. Grund dafür ist, dass die Erkenntnisse weniger wissenschaftlicher Natur sind und häufig durch einfache arbeitsorganisatorische Maßnahmen vermeidbar wären. Die potenziellen Fehlerquellen wurden in die fünf Kategorien „Methode“, „Maschine“, „Material“, „Mensch“ und „Milieu“ aufgeteilt, was eine etablierte Aufteilung in der Qualitätssicherung darstellt. Zusammenfassen lassen sich die Fehlerursachen in folgende Kategorien:

1. Begrenzte zeitliche und finanzielle Ressourcen

Die begrenzten Ressourcen führen dazu, dass Wartungsintervalle teilweise nicht eingehalten werden können oder bewusst gestreckt werden. Das ist teilweise darin begründet, dass die Herstellerangaben beispielsweise für Filter, Schutzgläser oder Kühlaggregate aufgrund fehlender Datengrundlagen und mutmaßlich ökonomischer Interessen die Wartungsintervalle sehr konservativ ausgelegt sind. Mit dieser Kenntnis werden von den Vorgaben abweichende Intervalle in der Praxis in Kauf genommen und auf subjektive Erfahrungswerte sowie Intuition vertraut. Auch vor diesem Hintergrund stellt die in AMalytik entwickelte datengestützte Qualitätssicherung einen interessanten Hebel dar, nämlich um ökonomisch sinnvollere Wartungsintervalle zu entwickeln, während die Bauteilqualität gewährleistet wird.

2. Unzuverlässige Sensorik

Teilweise liefern die eingebauten Sensoren der Anlagen unzuverlässige Messwerte. Ein Beispiel dafür sind die Sauerstoffsensoren, die den Sauerstoffgehalt innerhalb der Anlage vor und während des Druckvorganges überwachen. Trotz der Einhaltung der vorgegebenen Wartungsprotokolle verschmutzen diese vorzeitig und liefern keine realitätsgetreuen Messdaten. In der geschilderten Situation war der gemessene Sauerstoffgehalt kleiner als der tatsächliche, was zu einer gesteigerten Oxidation der Bauteile des Baujobs und damit zur Nichterfüllung einiger Qualitätsmerkmale führte. Vermeiden ließe sich auch diese Problematik durch die in AMalytik entwickelte datengestützte Qualitätssicherung. Dadurch könnten sich Anomalien im zeitlichen Verlauf der Sauerstoffmesswerte während eines Baujobs und damit ein Drift in der Bauteilqualität ermitteln lassen, der Anlass für die Überprüfung neuralgischer Komponenten in der Produktionsumgebung sein kann.

3. Unentdeckte Inkompatibilitäten der Softwares

Insbesondere durch die hohe Dynamik, mit der sich die additive Fertigung entwickelt, erscheinen immer neue Softwareupdates und auch Anlagengenerationen. Die Kompatibilität der Anlagen und Softwares zueinander ist in manchen Fällen nicht gegeben. Das führt teilweise schlicht zur unmöglichen Nutzung neu entwickelter Features. Wahrscheinlich noch problematischer ist die Nutzung einer Soft- und Hardwarekombination ohne die Kenntnis existierender Inkompatibilitäten. Beispielsweise kann das dazu führen, dass Laserscanvektoren nicht exakt den Weg befolgen, der vorgesehen ist. Das kann zu Lücken oder Doppelbelichtungen der Schmelzfläche und damit Bauteildefekten führen. Viele Anwender der additiven Fertigung begegnen diesem Problem mit der strikten Beibehaltung aller Soft- und Hardwarekomponenten, was dazu führt, dass die technologischen Potenziale der additiven Fertigung nicht oder nur mit einer erheblichen zeitlichen Verzögerung Anwendung in der breiten Masse der Fertiger finden.

4. Zu kleine Prozessfenster oder zu stark ausgereizte Produktivitätspotenziale

Die typische Herangehensweise bei der Entwicklung neuer Prozessparameter für ein Material oder eine Anwendung ist die iterative Annäherung an die Stellgrößen, wie Schichtdicke, Laserleistung und Laserscangeschwindigkeit. Die sich daraus ergebenden Prozessparameterfenster haben je nach Material eine unterschiedliche Spannweite. Je größer die Spannweite, desto robuster kann ein Schmelzprozess ausgelegt werden. Manche Materialien sind so schwierig zu verarbeiten, dass auch kleine Schwankungen in den Prozessbedingungen zu einer entscheidenden Verschlechterung der Bauteilqualität führen. Ein weiterer Grund für Anfälligkeiten von schwankenden Prozessbedingungen ist die Wahl eines Prozessparametersatzes, der mit dem Ziel optimierter Produktivität zu nah an dem Rand der Prozessparameterfensters positioniert ist. Das kann auch bei einem normalerweise robust verarbeitbaren Material der Fall sein.

5. Ungeeignete Umgebungsbedingungen

Ein weiteres Problem sind nicht geeignete Umgebungsbedingungen und Arbeitsmaterialien. Dazu zählt die Gebäudeinfrastruktur, beispielsweise die zuverlässige, stabile Versorgung mit Gasen, Luftdruck und Flüssigkeiten sowie ein stabiles Raumklima. Die Luftfeuchtigkeit sowie die Raumtemperatur müssen stets geregelt und kontrolliert sein. Weiterhin muss die Arbeitssicherheit unbedingt gewährleistet sein, allerdings ohne zu vernachlässigen, dass entsprechende Schutzausrüstung (Schuhe, Schutzanzug aus Tyvek-Material, Handschuhe sowie Kopf- und Atemschutz) bis zu acht Stunden am Tag getragen werden müssen. Ungeeignete, also auch unergonomische, Ausrüstung führt in diesem Falle schnell zu erheblichem Unbehagen, Ermüdung und schlussendlich erhöhtem Risiko für Unfälle und

qualitätsrelevante Fehler. Im weiteren Sinne zählen zu den Umgebungsbedingungen auch arbeitsorganisatorische Fragestellungen, wie beispielsweise,

6. Risikofaktor Mensch

Der wahrscheinlich kritischste Faktor für die Bauteilqualität in der additiven Fertigung ist, wie in vielen anderen Technologien auch, der Mensch. Insbesondere die additive Fertigung ist für menschliche Fehler anfällig, da viele Fertigungsschritte noch nicht automatisiert, standardisiert oder auch ausgereift sind und ein hohes Maß an Ausbildung, Erfahrung und in Teilen Geschick gefordert ist. Spezifisch auf die additive Fertigung ausgerichtete Ausbildungen werden noch nicht flächendeckend angeboten, auch wenn Handwerkskammern und Betriebe ihr Angebot stetig erweitern. Beispielsweise bietet das Fraunhofer IAPT seit dem Jahr 2024 eine Ausbildung im Bereich der additiven Fertigung an.

Viele der während der durchgeführten FMEA ermittelten Fehlerursachen sind auf den Faktor Mensch zurückzuführen. Zu diesen Ursachen zählen unter anderem die Verwendung der falschen Pulversiebe, fehlende oder unzureichende Reinigung vor dem Siebprozess, die Verwendung verschmutzter und damit häufig undichter Pulverbehältnisse, das unzureichende Entgraten der Bauplattform, Fehler in dem Einbau und der initialen Ausrichtung der Bauplattform, die falsche Montage der Beschichterklinge, ein falsch ausgewählter Pulverzuführungsfaktor in der Anlage, ein Nichteinhalten der Wartungsintervalle von Kühlkreisläufen, Laserquellen, der Anlage selbst und peripherer Infrastruktur, unzureichender Überblick über Materialvorräte in der Anlage sowie im Betrieb, nicht durchgeführter Austausch von Verbrauchsmaterialien – dazu zählen auch Laserschutzgläser –, unsachgemäße Vorgehensweise bei Wartung und Reinigung der Komponenten oder auch die fehlende Kenntnis der maschinenindividuellen Eigenheiten. Weiterhin gibt es indirekte menschliche beziehungsweise organisatorische Fehler, wie die unzureichende Organisation, Durchführung und Kommunikation von Wartungsarbeiten durch externe Techniker.

Vielen dieser Probleme kann durch eine entsprechende Sensibilisierung und Ausbildung der Mitarbeiter sowie geeignete Arbeitsanweisungen und Protokolle entgegengewirkt werden. Weiterhin ist zu beachten, dass nur eingewiesene Personen Anlagen bedienen dürfen und auch der Erfahrungsschatz der Mitarbeiter zu berücksichtigen ist. Eine offene und in geringem Maße strafende Fehlerkultur hilft, Fehler offen zu kommunizieren und in der Zukunft zu vermeiden. Auch die datengestützte Qualitätssicherung kann sehr gut zur Vermeidung menschlicher Fehlerursachen dienen, da Vorkommnisse (zum Beispiel Wartungen, Software- oder Hardwareupdates etc.) und Prozessschwankungen miterfasst werden können und entsprechende Rückschlüsse zu ziehen sind. Es ist allerdings sehr wichtig, die Persönlichkeitsrechte zu berücksichtigen.

AP1.2 Entwicklung geeigneter Probekörper zur gezielten Defektprovokation (prozessübergreifende Defekte)

Ergänzend zur ursprünglichen Planung konnte das IAPT anhand des vorangegangenen Forschungsprojekts SonicQuality [FKZ: 03LB5010C] Erfahrungswerte und Ansätze zur gezielten Provokation von Rissen einbringen. Neben dieser Unterstützung im Konsortium fand keine wesentliche Ausarbeitung oder Ähnliches statt. Insofern wird dieses Arbeitspaket nicht weiter ausgeführt.

AP1.3 Datenerfassung zum Aufbau einer fundierten Datenbasis entlang der gesamten Prozesskette und Ermittlung von Datenlücken

Das Ziel dieses Arbeitspakets besteht darin, eine umfassende und verlässliche Datenbasis zu schaffen, die den additiven Fertigungsprozess detailliert abbildet. Dabei werden die Datenflüsse während dieses Prozesses genau identifiziert, um mögliche Lücken aufzudecken. Es soll explizit ermittelt werden, welche spezifischen Daten und Informationen in den verschiedenen Prozessschritten generiert werden und welche Datenschnittstellen existieren oder fehlen. Sollten Datenschnittstellen fehlen, wird angestrebt, geeignete Schnittstellen zu implementieren, um jegliche Datenlücken im Qualitätssicherungskonzept zu schließen. Ein weiterer Fokus liegt auf der Erfassung des aktuellen Digitalisierungsgrades innerhalb des Prozesses. Durch die Durchführung mehrerer Baujobs auf einer festgelegten Anlage, bei denen die Einflussgrößen gezielt variiert werden (AP 1.1), soll eine solide Datenbasis geschaffen werden. Diese Datenbasis dient als Grundlage für die Erprobung von KI-gestützten Qualitätssicherungsmethoden. Zudem ermöglicht sie die Untersuchung der Auswirkungen der im AP 1.1 ermittelten Einflussgrößen auf die Critical-to-Quality-Parameter (CTQs).

Im gegenwärtigen Berichtszeitraum wurden bei der toolcraft AG Baujobs durchgeführt, die verschiedene Defektarten umfassten. Die Analyse und Prüfung der platzierten Forschungsobjekte, Zugproben und Schliffstäbe fand ebenfalls bei Toolcraft statt. Parallel zur Fertigung und Prüfung der Baujobs begann die toolcraft AG, zusammen mit den Projektpartnern IAPT und AMsight, relevante Prozess- und Anlagendaten zu sammeln. Dabei wurden umfassend alle Prozessdaten erfasst, darunter metallographische und morphologische Daten sowie Analysen, Prozessparameter der TP3000, Post-Process-Daten (zum Beispiel Berichte zum Lösungsglühen und Aushärten) und der Magics-Export von CAD-Daten der Baujobdesigns. Diese Daten wurden zunächst in der OwnCloud gesammelt und anschließend in eine interaktive Datenbank übertragen.

Alle hergestellten Baujobs wurden in amsight erfasst und allen Projektpartnern über ein Web-Interface zugänglich gemacht. Neben den 3D-Druck Parametern, wie Laserscangeschwindigkeit, Laserleistung, Scanpfadbreite oder z-Position der Strahltaille, sind

alle qualitätsrelevanten Parameter aus der Nachbearbeitung und Qualitätsprüfung in amsight erfasst (s. Abbildung 1).

Die Daten werden dabei über verschiedene Schnittstellen in die amsight Software eingespeist:

-Informationen über die Baujobzusammensetzung, Geometrie und Positionierung der Bauteile wird über das 3MF-Format in amsight importiert

-Informationen zu den Prozessparametern werden über Maschinenprotokolle ausgelesen

-Qualitätsdaten und Daten aus der Nachbearbeitung werden ebenfalls über eigens entwickelte Importer automatisch über ein Import-File ausgelesen

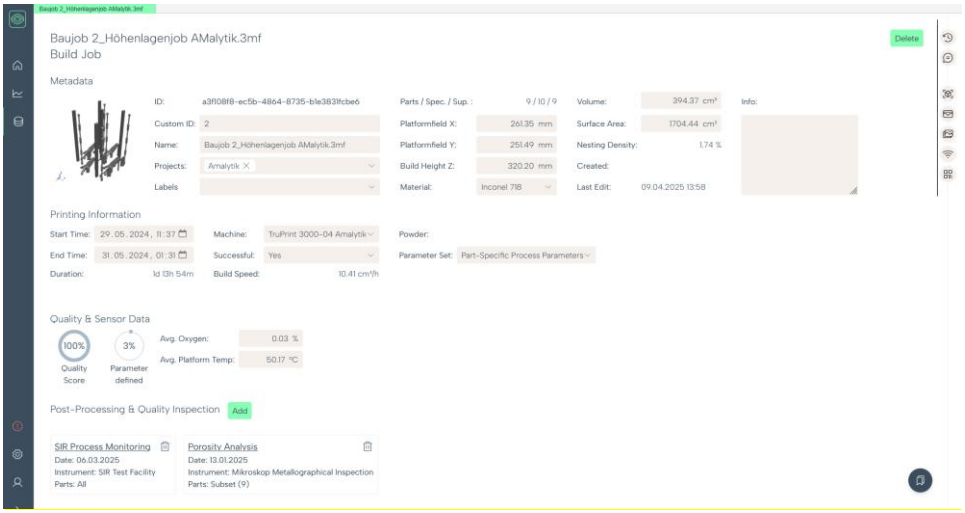

Abbildung 1: Beispielhafte Darstellung des Höhenlagenbaujobs in der amsight Software

Zusätzlich wurde eine Live-Datenerfassung der Maschinendaten mit dem WZL erfolgreich getestet und implementiert, über die Sensor- und Prozessdaten direkt aus dem 3D-Druck erfasst werden können. Auf diese Weise wird die Grundlage für eine Live-Überwachung gelegt und perspektivisch auch das Eingreifen in den laufenden Fertigungsprozess ermöglicht.

In amsight sind alle diese Daten rückverfolgbar dokumentiert und für alle Nutzer zugänglich. Dadurch können alle Projektpartner die Daten für Ihre Entwicklungen effizient nutzen (s. Abbildung 2). Dafür wurde eine offene API zur Verfügung gestellt, die einen Vollzugriff auf alle Daten ermöglicht.

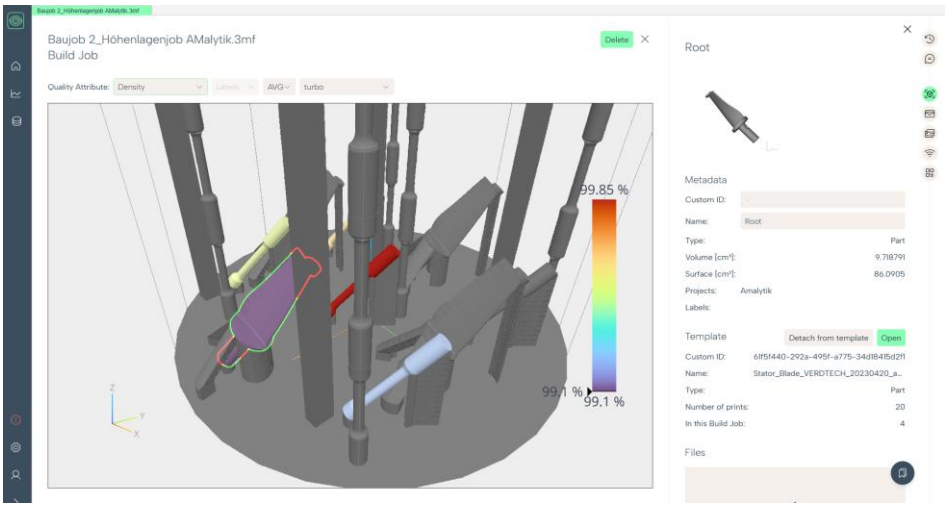

Abbildung 2: Visualisierung von Dichte-Messwerten in amsight

AP 1.4 Pilotlinienumsetzung durch Integration der AMalytik Teil-entwicklungen in die betrachtete AM Prozesskette

Es wurde ein einheitliches User-Interface entwickelt, was eine flexible und intuitive Konfiguration von Nachbearbeitung und Messsystemen durch den User ermöglicht. Dabei kann der Anwender selbst entscheiden, welche Prozessparameter (z.B. Bearbeitungsparameter) oder Qualitätsdaten (z.B. Sensorwerte oder mechanische Eigenschaften) er für die jeweilige Maschine aufnehmen und speichern möchte. Die Schnittstelle zur Aufnahme dieser Daten kann ebenso flexibel programmiert werden, s. Abbildung 3 (z.B. Live-Datenerfassung oder Auslesen von Daten aus Messprotokollen oder Log-Files).

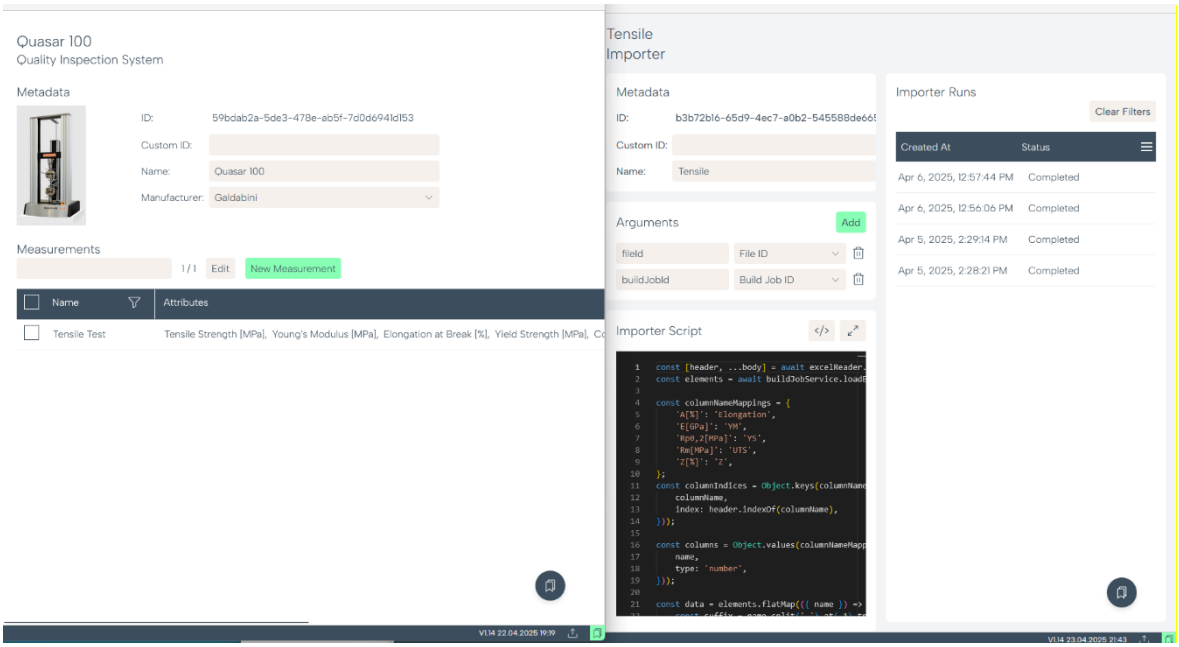

Abbildung 3: Messgerät für Zugprobenprüfung in amsight (links), sowie Importer für Ergebnis-File in amsight (rechts).

AP3.5 Erprobung von KI-Auswertealgorithmen

Dieses Arbeitspaket basierte auf den Entwicklungen von GE Additive. Es wurden Algorithmen entwickeln, die in der Lage sind im Raum des CAD-Bauteilmodells Zonen bzw. Volumina mit einer hohen Wahrscheinlichkeit für das Vorhandensein einer Anomalie (Risikozonen) zu definieren. Zu diesen Anomalien zählen auch Defekte, wie Poren oder Risse. Um Korrelationen zwischen den Risikozonen und tatsächlich vorhandenen Defekten zu ermöglichen, wurden CT-Scans zur Hilfe genommen, mit denen Defekte entdeckt werden

konnten. Die CAD-Modelle inklusive der Risikozonen wurden räumlich über die CT-Scans gelegt. Eine entscheidende Schwierigkeit hierbei waren die Formabweichungen in den CT-Scans, die aufgrund des Aufbauprozesses im L-PBF zustande kamen. Namentlich ging es um Abweichungen wegen thermisch bedingter Verzüge des Bauteils. Um einen direkten Vergleich zu ermöglichen, mussten die CT-Scans bzw. CAD-Modelle also mittels Algorithmen so verzerrt werden, dass sie genau auf den komplementären Datensatz passten. Das Fraunhofer IAPT unterstützte bei der Auswertung der Daten, indem es sein wissen über Signalsignaturen sowie geometrische Korrekturalgorithmen mit GE Additive teilte und in Workshops Ansätze für die Auswertetools entwickelte.

AP4.3 Automatisiertes Management von Datenströmen

AP 4.3 wurde vom WZL geführt; das IAPT unterstützte konzeptionell (Protokollwahl, Topic-/Payload-Konventionen, Security, Anschluss an HAP 5 und AP 4.4). Es wurde eine Live-Datenübertragung zwischen einem Ender3 3D-Drucker (WZL) und der amsight-Software realisiert. Als Kommunikations-Schnittstelle wurde MQTT verwendet, welche die Übertragung der qualitätsrelevanten Daten wie Prozessparameter, Sensordaten und Meta-Informationen ermöglicht. Über die Schnittstelle können Daten direkt in die amsight-Datenbank geschrieben werden, ohne User-Interaktion. Aus Eignungssicht überzeugt MQTT durch Leichtgewichtigkeit und das Publish/Subscribe-Prinzip sowie konfigurierbare Zustellgarantien (QoS). Für Betrieb und Governance sind TLS/mTLS, ACLs, Retained/LWT sowie versionierte Payload-Schemata und hierarchische Topics zu empfehlen. Hochfrequente Rohdaten sollten out-of-band gespeichert und über MQTT nur als Events/Metadaten/Verweise übertragen werden. Die Trennung von Transport und Semantik, mit modellierten Sensorbeschreibungen und stabilen IDs/UTC-Zeitstempeln, erleichtert das automatisierte Matching von Quellen und Senken. Empfohlen werden MQTT 5 und JSON für eine effiziente Umsetzung. Fazit: MQTT ist ein tragfähiges, erweiterbares Rückgrat für das Datenstrom-Management.

AP4.4 Digitale Zertifizierung der Messdaten

Ziel von AP 4.4 war es, die Rückführbarkeit der in HAP 4 definierten Metadaten durch digitale Zertifikate abzusichern. Das IAPT unterstützte das WZL dabei mit branchenspezifischem Wissen und methodischer Begleitung. Wir haben eine risikobasierte Definition und Priorisierung „vertrauenswürdiger“ Daten für die Pilotlinie mit erarbeitet (u. a. Kalibrierzertifikate, Prüfmittel-/Sensorstatus, Software-/Firmwarestände, Umgebungsbedingungen, Prozessparameter) und regulatorische Anforderungen aus der Luftfahrt eingebracht. Die zugrundeliegenden Verifizierungsdokumente durften nicht direkt

bereitgestellt werden; ihre Inhalte sind jedoch in Kriterien, Prozesse und Prüfpunkte eingeflossen.

Für die Einbindung in die Systeminfrastruktur wurden Integritäts- und Authentizitätsanforderungen abgestimmt (kryptografische Signaturen/Hashes, Zeitstempel, Provenienz, eindeutige IDs) und Referenzfelder zur Verknüpfung von Messdaten mit digitalen Kalibrierzertifikaten vorgeschlagen (z. B. certificate_id, issuer, validity, signature_ref, payload_hash). Das IAPT begleitete Reviews zu Konzepten und Demonstratoren der „doppelten Rückführbarkeit“ und definierte Abläufe für Erstellung, Aktualisierung und Auditfähigkeit.

Die Hauptergebnisse des Arbeitspakets, einschließlich der Demonstration der digitalen Kalibrierzertifikate und der doppelten Rückführbarkeit, sind beim WZL dokumentiert. Aus IAPT-Sicht ist die digitale Zertifizierung ein praktikabler Baustein zur Sicherstellung von Integrität, Nachvollziehbarkeit und Konformität im AMalytik-Workflow.

AP5.1 Aufbereitung der Daten und Entwicklung des Qualitätsdatenmodells

Das Ziel des Arbeitspakets besteht darin, den AM Fertigungsprozess im Allgemeinen und im Projekt speziell für L-PBF zu untersuchen, um ein Qualitätsdatenmodell zu entwickeln. Dieses Modell soll anschließend als Backend umgesetzt werden.

Die konzeptionelle Untersuchung der Technologie sowie der entstehenden Metadaten hat in engem Zusammenspiel mit der Bearbeitung der weiteren datenbezogenen Arbeitspakete, insbesondere 1.1 und 4.1, stattgefunden. Der L-PBF Prozess wurde intensiv studiert und in Hinblick auf entstehende Dateninhalte und Datenformate analysiert.

Hierbei handelt es sich um relationale Datenbanken basierend auf der structured query language (SQL). Diese Datenbanksysteme bieten den Vorteil logische Verbindungen und Abhängigkeiten sehr gut abbilden und parallel Datenquellen, Prozessschritte oder sonstige Themenfelder durch die Erstellung spezifischer Tabellen voneinander abgrenzen zu können. Insofern können einzelne Datenpunkte sowie Relationen eindeutig identifiziert und Strukturen gut dargestellt werden (Kemper & Eickler, 2015, 73ff., 116ff.). Nach umfangreicher Prüfung wurde die grundlegende Architektur als passend bewertet. Anpassungen und Erweiterungen in Hinblick auf die Anforderungen im Rahmen des Projekts sowie Optimierungspotenzial in Bezug auf Lesbarkeit, Granularität und Effizienz wurden aufgenommen.

Über die offene API in amsight, können sämtliche Daten, die sich in amsight befinden, ausgewertet und analysiert werden. Durch die einheitliche und strukturierte Datenablage bietet

amsight eine ideale Voraussetzung, um Wirkzusammenhänge mittel statistischer und KI-Basierte Methoden zu ermitteln.

Beispiele für eine Datenauswertung sind z.B. die Datenvisualisierung von z.B. Sensordaten, die Daten können räumlich visualisiert werden (z.B. Sensordaten), die Korrelationsanalyse von Prozessparametern (CTPs) und Qualitätsparametern (CTQs) oder aber die Ermittlung von Einflüssen unterschiedlichster Einflussparameter auf Qualitätsgrößen mittels KI. Beispiele dafür sind in Abbildung 4 dargestellt.

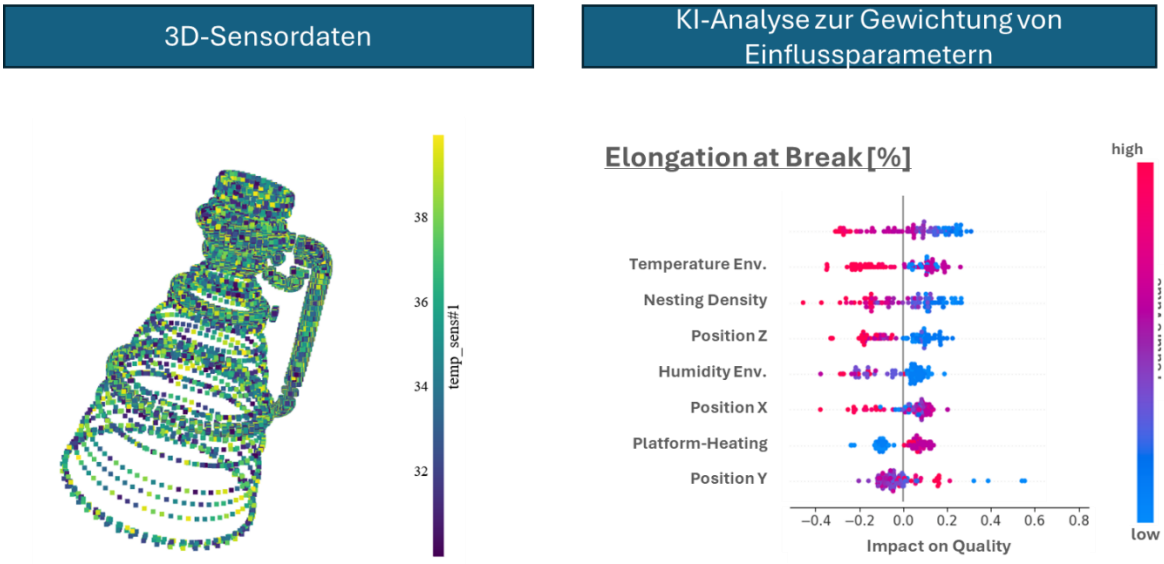

Abbildung 4: Beispiel von 3D-Datenvisualisierung (links) und KI-Analyse zur Gewichtung von Einflussparametern auf die Bauteilqualität (CTQs)

AP5.2 Entwicklung und Implementierung der Systeminfrastruktur sowie des Userinterfaces und der Gegenschnittstellen zu HAP4, HAP3 und HAP2

In diesem Arbeitspaket wird die IT-Infrastruktur des Datenbanksystems inklusive der zugehörigen Programmierschnittstellen (API, engl. Application Programming Interfaces) zur Gewährleistung der sicheren Kommunikation der verschiedenen Programme und Systeme im Projekt umgesetzt. Insbesondere die Entwicklung und Implementierung der maßgeschneiderten Schnittstellen, sowie deren Wartung ist für eine erfolgreiche Integration der Metadaten der Projektpartner entscheidend.

Die offene API in amsight ermöglicht ein Vollzugriff auf alle Daten in amsight. Zusätzlich können über die integrierte Code-Umgebung können in Python eigene Analyse-Skripte geschrieben und auch im gesamten Projektteam geteilt werden.

Die Wartung der API und Code-Umgebung wird durch amsight sichergestellt. Ebenso wurden Wünsche von Projektpartner zur Verbesserung und Vereinfachung der Handhabung laufend umgesetzt.

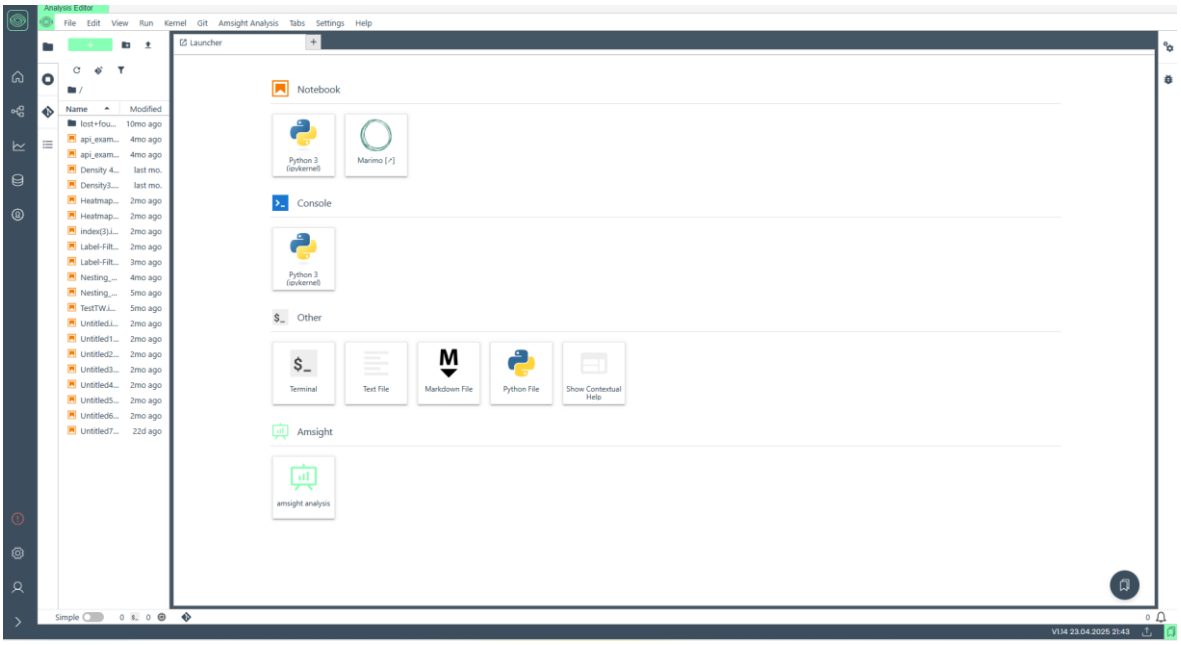

Abbildung 5: Code-Umgebung zur Entwicklung eigener Analyseskripte in amsight mit Vollzugriff über die offene API

Zusätzlich zu der offenen Code-Umgebung, die eine eigene Entwicklung von Analyse-Skripten ermöglicht, gibt es vorgefertigte Analysen, die genutzt werden können und insbesondere Einblicke hinsichtlich Prozessstabilität in der Fertigung ermöglichen (vgl. Abbildung 6).

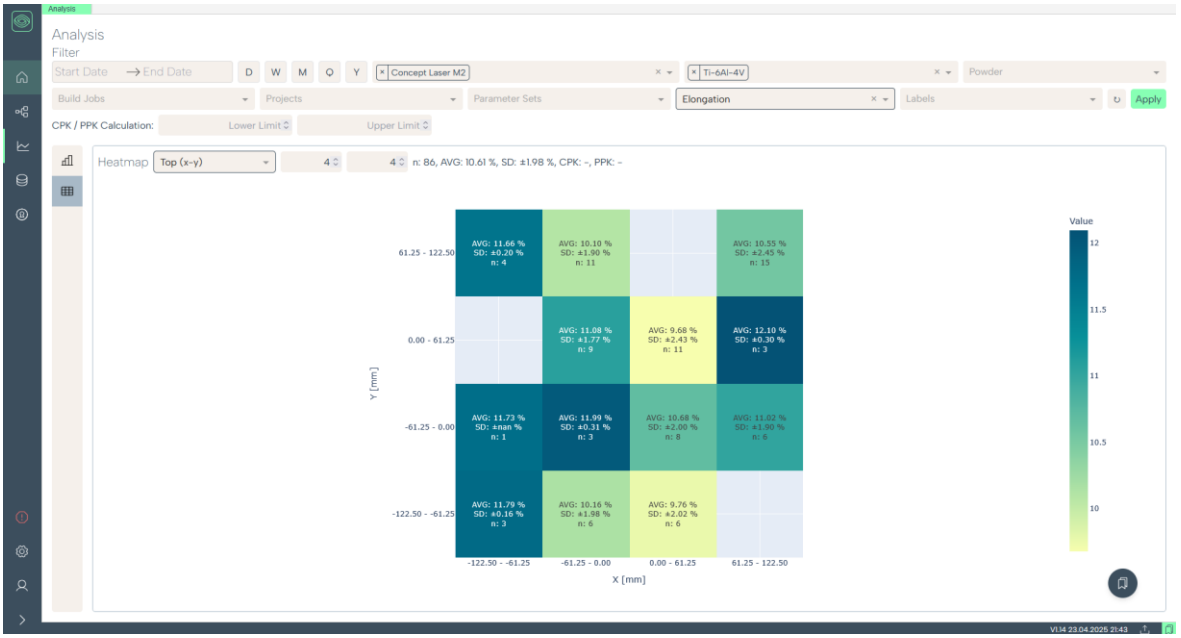

Abbildung 6: Darstellung der Bauteilqualität in Abhängigkeit von der Positionierung der Bauteile auf der Bauplattform in amsight

Weiterhin lassen sich die gefertigten Baujobs dreidimensional darstellen und die mit den Bauteilen verknüpften Eigenschaften mittels einer Farbskala anzeigen:

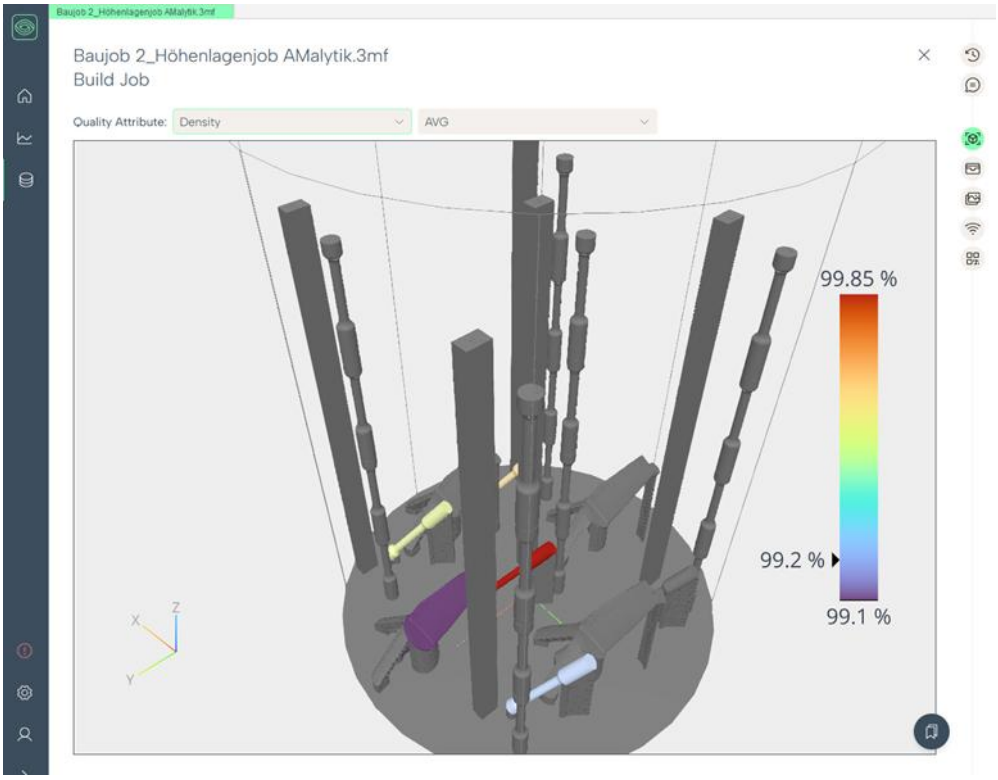

Abbildung 7: 3D-Darstellung und Visualisierung der Messdaten in der Datenbank

Die folgende Abbildung zeigt das User-Interface mit der eingebundenen Anlage bei Toolcraft, einer exemplarischen Anlage zur Demonstration der automatischen Datenübertragung sowie einen Beispielbaujob inkl. dokumentierter Nachbearbeitungsschritte

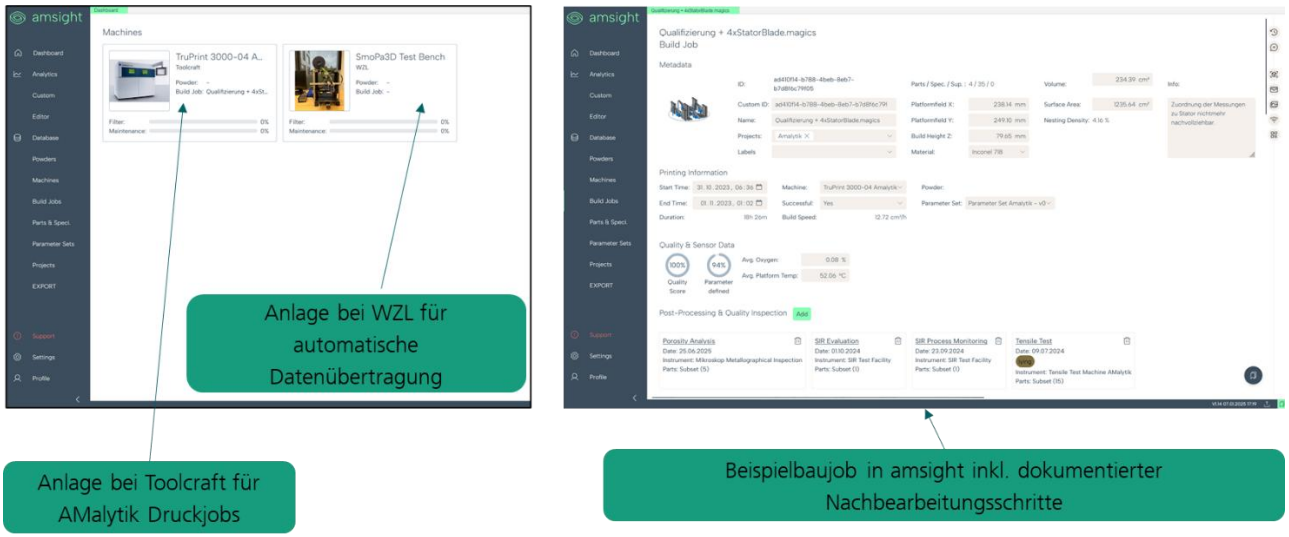

Abbildung 8: User-Interface zur Dokumentation von AM-Baujobs

Es folgen weitere Funktionen, die für die Datenbank im Rahmen des Projektes entwickelt wurden:

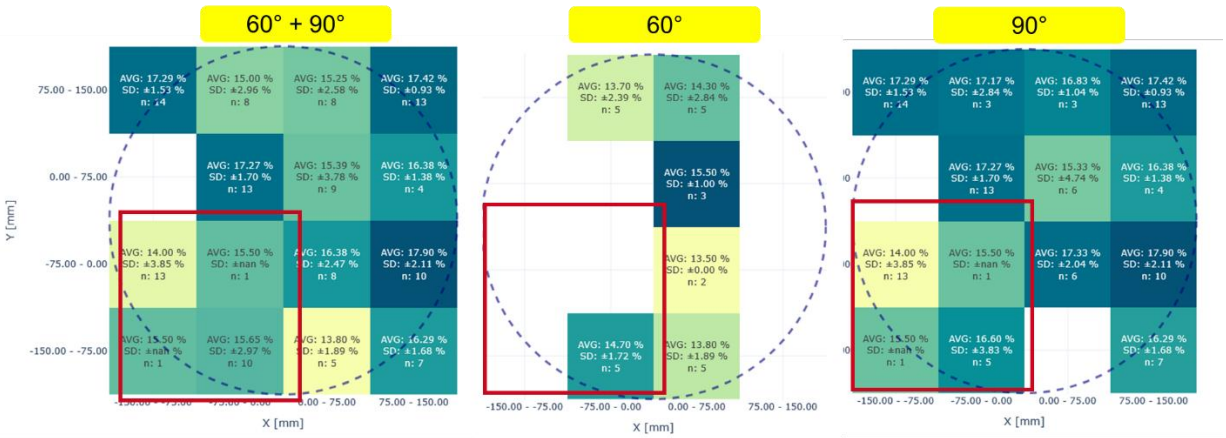

Abbildung 9: Vergleich der Zugfestigkeit in Abhängigkeit der Position

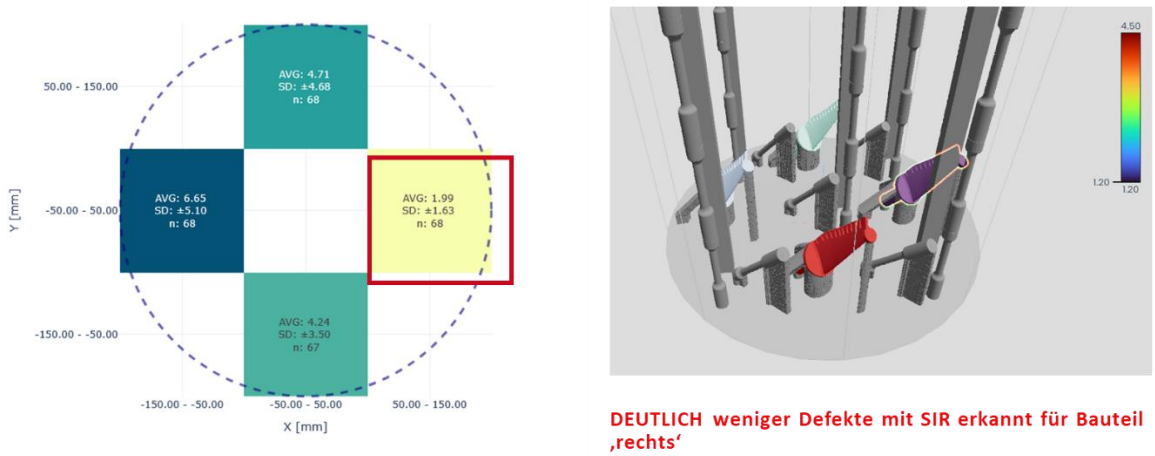

DEUTLICH weniger Defekte mit SIR erkannt für Bauteil ‚rechts'

Abbildung 10: Vergleich der Number of Defects (SIR) in Abhängigkeit der Position

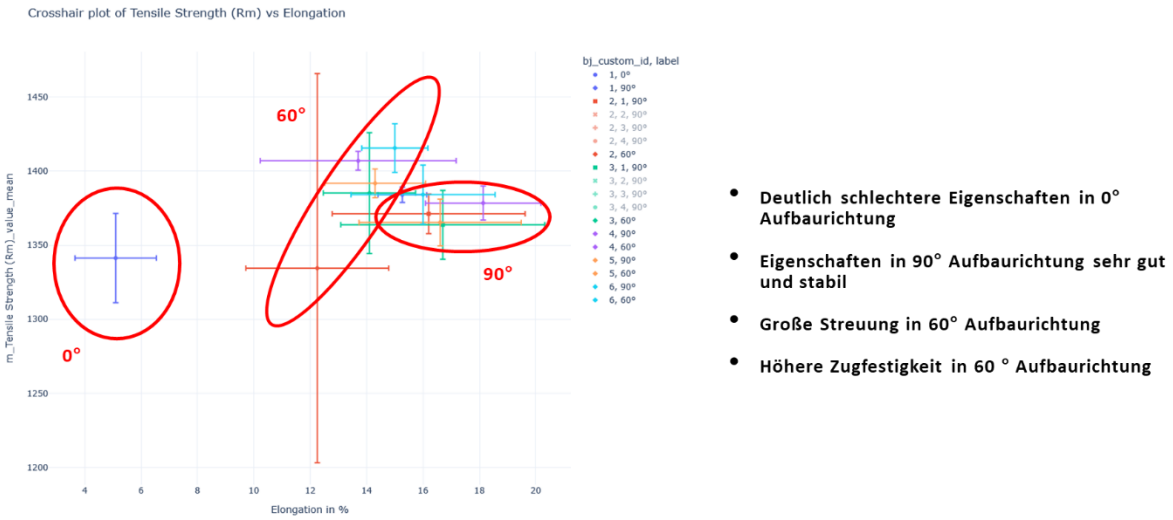

Abbildung 11: Mechanische Eigenschaften in Bezug auf die Aufbaurichtung

AP5.3 Konzeptionelle Untersuchung von KI-Methoden zur Analyse bzw. Ermittlung qualitätsrelevanter Einfluss- und Störgrößen

Die vorangegangenen Arbeitspakete zur Sammlung und zur effizienten, strukturierten Speicherung der Metadaten entlang des additiven Fertigungsprozesses bilden die tragfähige Grundlage für die Kernziele dieses APs. Auf Basis der projektspezifischen Datenbank wurden Qualitätsanalysen konzipiert und umgesetzt, die auf höhere Bauteilqualitäten und geringere Ausschussmengen zielen. Die Bearbeitung des Arbeitspakets wurde zeitlich vorgezogen, um bereits früh – gestützt auf die bekannten, voraussichtlichen Datenformate, -inhalte und -mengen – konzeptionelle Überlegungen anzustellen und sicherzustellen, dass alle hierfür benötigten Daten rechtzeitig und vollständig gespeichert werden.

Ein zentrales projektspezifisches Merkmal ist die zu erwartende begrenzte Datenmenge in Bezug auf die Anzahl gefertiger Proben. Dies ist darauf zurückzuführen, dass für das Projekt bewusst spezielle Baujobs gefahren werden, um einheitliche Rahmenbedingungen (Baujobdesign, Ausgangsmaterial, Fertigungsanlage) sicherzustellen und zugleich explizit definierte Defekte einbringen und analysieren zu können (AP1.2). Da die in AP1.1 definierten CTQs im Schwerpunkt mechanische Eigenschaften sind, die über zerstörende Prüfverfahren ermittelt werden, entsteht pro Probekörper genau ein Qualitätsdatenpunkt. Die Anzahl der Qualitätsdatenpunkte entspricht somit der gefertigten Probenzahl und bewegt sich im zwei- bis kleinen dreistelligen Bereich.

Vor diesem Hintergrund wurde früh die Frage adressiert, wie KI-Analysen trotz kleiner Stichproben robust und aussagekräftig gestaltet werden können. Es wurden

Datenaugmentationsstrategien identifiziert und vorbereitet, um die nutzbare Datenbasis gezielt zu vergrößern beziehungsweise robuster zu machen: Resampling/Bootstrapping, das Einbringen kontrollierten Rauschens als künstliche Störgröße, regelbasierte Zufallsdatengenerierung auf Basis von Expertenwissen, Monte-Carlo-Simulationen auf Grundlage vorhandener Projektdaten, vorlaufender Projekte sowie einschlägiger Literatur, und ergänzend algorithmische beziehungsweise KI-gestützte Ansätze. Alle Verfahren unterscheiden sich hinsichtlich Qualität, Vor- und Nachteilen sowie notwendigen Voraussetzungen; eine kombinierte Anwendung ist vorgesehen, um die jeweiligen Stärken zu nutzen. Besonders vielversprechend erwies sich aus Sicht des Berichtsjahres das Hinzufügen weißen Rauschens (white noise) mit Mittelwert null auf ausgewählte Variablen und die regelbasierte Generierung synthetischer Daten auf Basis von Expertenwissen. White noise ist definitionsgemäß ein unkorrelierter, reeller und stationärer stochastischer Prozess von Zufallsvariablen (vgl. Michael Falk et al., 2012, S. 49); durch die Addition solcher Zufallszahlen mit neutralem Mittelwert lässt sich die Ausprägung einzelner Variablen variieren, ohne das arithmetische Mittel der Verteilung zu verändern. Die Streuung steigt dabei gezielt an, sodass Hypothesen über die Auswirkungen auf Qualitätskennwerte zu formulieren und vorab datenbasiert zu prüfen sind, da diese Annahmen die Trainingsdaten und damit die Modellergebnisse beeinflussen. Ähnliche Vorarbeiten sind für Monte-Carlo-Simulationen erforderlich, da diese auf Annahmen zu Wahrscheinlichkeitsverteilungen der Variablen beruhen (Thomopoulos, 2013). Bootstrapping wird klassisch eingesetzt, um die Güte von Schätzern und Teststatistiken zu quantifizieren, indem aus einer Stichprobe wiederholt Teilstichproben mit Zurücklegen gezogen und die Zielgrößen berechnet werden; auf Basis der Vielzahl an Schätzern lassen sich etwa Konfidenzintervalle bestimmen (Boos, 2003; Chernick et al., 2011). Diese Form des Resamplings kann – über ihren originären Zweck hinaus – auch zur Datenvervielfältigung dienen (Yu, 2002). Dabei werden keine neuen Informationen erzeugt, wohl aber erhalten einzelne Beobachtungen mehr Gewicht, und unterschiedliche künstliche Stichprobenerweiterungen lassen sich systematisch vergleichen. Bei KI-basierten Ansätzen stellt die geringe Datenmenge erneut eine Herausforderung dar; die Kombination mehrerer Methoden hat sich in anderen Anwendungsdomänen als vielversprechend erwiesen (Pereira Parente et al., 2019) und wurde daher auch hier vorbereitet und gezielt eingesetzt. Ergänzend wurde die Integration von Unsicherheiten als methodischer Baustein berücksichtigt, etwa durch den Einsatz von Gaussian Process Regression (Hermann et al., 2023), um Analysen bei kleinen Stichproben mit expliziter Unsicherheitsrepräsentation zu ermöglichen.

Parallel wurden Strategien erarbeitet, wie Qualitätsanalysen auch ohne konkrete Pulvermesswerte belastbar gestaltet werden können. Hintergrund sind projektexterne

Einschränkungen bei der Verfügbarkeit und Teilbarkeit detaillierter Pulvereigenschaften. In der Folge wurden deskriptive Analysen und statistische Auswertungen entwickelt und mit dem Eintreffen mehrerer Datensätze schrittweise angewendet, um Auffälligkeiten zu identifizieren, Hypothesen zu Wirkzusammenhängen abzuleiten und erste datengetriebene Handlungsempfehlungen zu formulieren. Diese Basisanalysen dienten als Sprungbrett für die nachgelagerte Modellierung und die Ableitung qualitätsrelevanter Einflussgrößen und Störfaktoren.

Die technische Infrastruktur erwies sich dabei als förderlich: Aufgrund der offenen API bestanden keine Beschränkungen hinsichtlich der Anwendbarkeit spezifischer KI-Algorithmen. Die einheitliche, strukturierte Datenbank von amsight stellte eine ideale Voraussetzung dar, um KI-Modelle auf Basis der konsolidierten Daten zu trainieren und zu testen. Im Rahmen des Arbeitspakets wurden Methoden zur Identifikation qualitätsrelevanter Einfluss- und Störgrößen konzipiert, implementiert und bewertet. Angesichts der projektbedingt kleinen Datensätze wurden Verfahren mit robuster Performance bei begrenzter Datenlage priorisiert. Die oben skizzierten Augmentierungsstrategien – Resampling/Bootstrapping, kontrolliertes Rauschen, regelbasierte Generierung und Monte-Carlo-Simulationen – wurden als begleitende Maßnahmen vorbereitet, um Modellstabilität und Generalisierungsfähigkeit zu erhöhen und Sensitivitätsanalysen zu ermöglichen.

Auf Modellseite wurden insbesondere Support Vector Regression (SVR) und Random-Forest-Regression untersucht. In den Vergleichstests zeigte Random Forest die bessere Performance und wurde daher als bevorzugtes Verfahren für die initiale Modellierungsstufe ausgewählt. Zur Erklärbarkeit der Vorhersagen kam SHAP (SHapley Additive exPlanations) zum Einsatz. Mit SHAP wurden die Beiträge einzelner Eingangsvariablen zur Zielgröße transparent gemacht, wodurch nachvollziehbar wurde, welche Prozess- und Umgebungsfaktoren maßgeblich auf die CTQs wirken. Aus diesen Einsichten wurden „Quality Gates“ abgeleitet, also umsetzbare Schwellwerte und Prüfregeln, beispielsweise für Umweltbedingungen, die Nesting-Dichte oder die Bauteilposition im Bauvolumen.

Um die methodischen Entscheidungen unabhängig von der in AMalytik verfügbaren Datenmenge abzusichern, wurden zusätzlich umfangreiche Fertigungsdaten aus einem Referenzvorhaben herangezogen. Diese umfassten mehr als 600 Baujobs, über 1.800 Zugproben und Daten von sieben Druckern. Die externe Validierung diente dazu, die Modellwahl und die Pipeline-Entscheidungen – vom Preprocessing über das Training und die Validierung bis hin zur Modellinterpretation – auf eine breitere empirische Basis zu stellen und Übertragbarkeit sowie Robustheit zu prüfen.

Das Ergebnis des Arbeitspakets ist eine belastbare, modulare Methodenbasis, die eine durchgängige Pipeline vom Datenimport und -vorverarbeitung über das Training und die Validierung bis hin zur Interpretation und zur Ableitung operativer Maßnahmen umfasst. Die Pipeline integriert datenökonomische Strategien für kleine Stichproben (Augmentierung, Unsicherheitsmodellierung) mit leistungsfähigen, erklärbaren Lernverfahren (insbesondere Random Forest in Kombination mit SHAP) und stützt sich auf eine flexible Infrastruktur (offene API, strukturierte amsight-Datenbank). Zugleich wurden die Besonderheiten der projektspezifischen Datenerhebung berücksichtigt: die gezielt kleinen, aber konsistenten und interpretierbaren Datensätze aus speziellen Baujobs, die Einbettung expliziter Defekte zur Hypothesentests und die Rahmenbedingungen der zerstörenden Prüfungen, die pro Probekörper einen Qualitätsdatenpunkt liefern.

In Summe konnte das Arbeitspaket den Übergang von der frühen, vorausschauenden Konzeption – mit dem Ziel, notwendige Daten vollständig zu erfassen – zur praktischen Umsetzung vollziehen: Die Methoden zur Ermittlung qualitätsrelevanter Einfluss- und Störgrößen wurden spezifiziert, prototypisch implementiert, auf projektexternen Referenzdaten validiert und in eine anwendungsreife Pipeline überführt. Mit den daraus abgeleiteten Quality Gates und den vorbereiteten Datenaugmentierungs- und Unsicherheitsbausteinen liegt eine tragfähige Grundlage vor, um auch unter Datensparsamkeit robuste, erklärbare Qualitätsanalysen zu betreiben, Auffälligkeiten frühzeitig zu erkennen und datenbasierte Handlungsempfehlungen für stabile Prozesse, höhere Bauteilqualität und geringere Ausschussmengen abzuleiten.

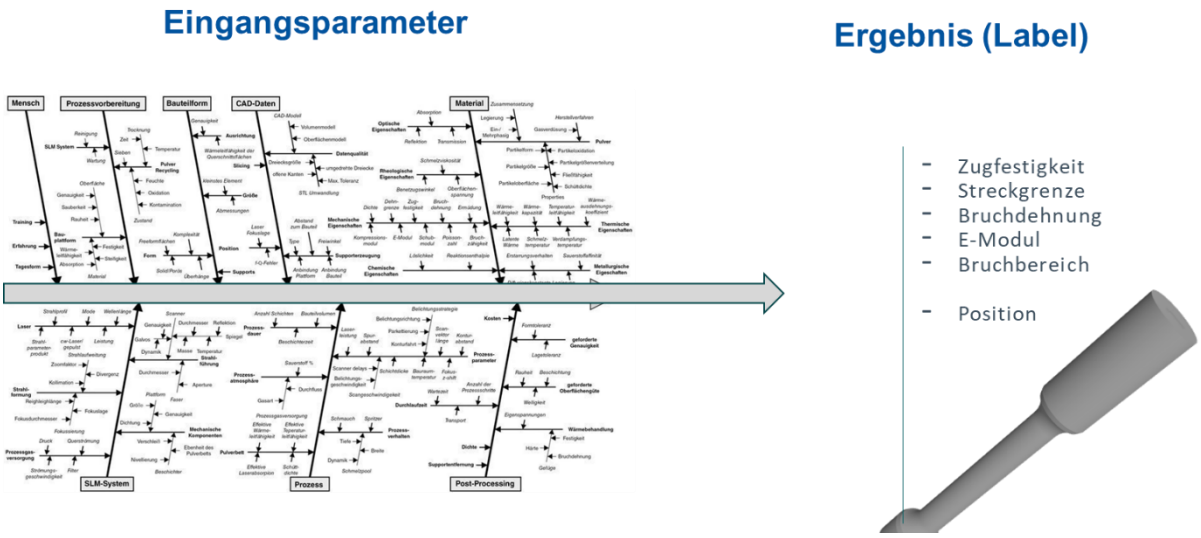

Abbildung 12: Konzeptionelle Darstellung von Eingangsparametern - in diesem Fall alle Einflussgrößen auf die Bauteilqualität und die Ergebnisse - in diesem Fall die gemessenen Qualitätsparameter, wie z.B. Zugfestigkeit

AP5.4 Entwicklung einer automatisierten KI zur adaptierbaren Qualitätsdatenanalyse

Aufbauend auf AP 5.1–5.3 wurde eine automatisierbare Analysekette implementiert: Datenzugriff über die offene API, Aufbereitung (Validierung, Deduplikation, Feature-Engineering), Modelltraining und Inferenz (u. a. Random Forest), SHAP-basierte Interpretation sowie Reporting und Visualisierung im Web-Frontend. Die Umsetzung erfolgt in der integrierten Code-Umgebung als wiederverwendbare Skriptmodule, sodass Analysen reproduzierbar, parametrierbar und teilautomatisiert ablaufen. Anwendungsgrenzen wurden dokumentiert (Datenumfang, Messgrößen-Abdeckung); gleichzeitig wurde ein Nachtrainings- und Skalierungskonzept definiert. Die im Antrag adressierte adaptierbare, automatisierte Auswertung steht damit prototypisch im amsight-Framework zur Verfügung.

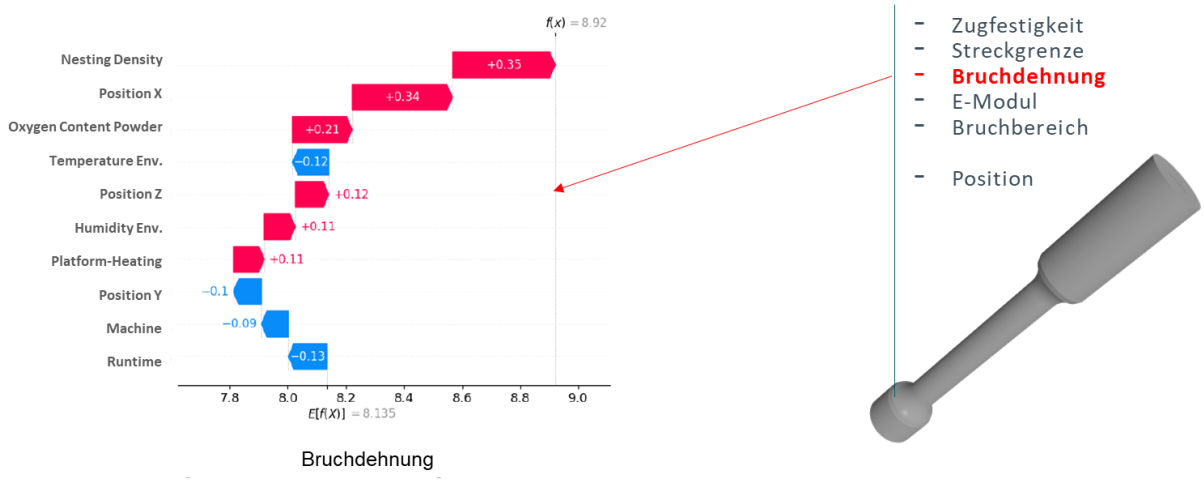

Abbildung 13: SHAP-Analysen für den konkreten AM-Anwednungsfall können Beitrag einzelner Eingangsvariablen zum Endergebnis vorhersagen bei KI-Modellen

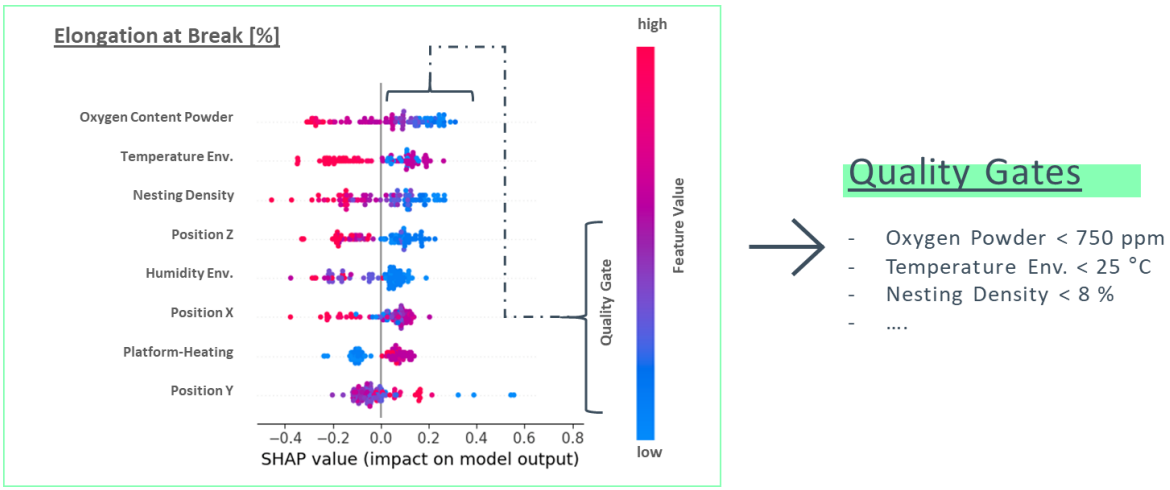

Abbildung 14: Anwendung von SHAP: Man kann den durchschnittlichen Beitrag der Einflussgrößen auf die CTQ (Qualitätsgrößen) anzeigen und daraus Quality Gates definieren

AP6.1 Physischer Demonstrator, Umsetzung und Bewertung anhand der KPIs

Das Fraunhofer IAPT unterstützte das Konsortium bei der Auswahl eines geeigneten Demonstratorbauteils sowie bei der Ermittlung qualitätskritischer Prozessparameter.

In Abstimmung mit den assoziierten Partnern GE-Aviation und Airbus wurden zunächst Anforderungen an das Forschungsobjekt definiert (u. a. geometrische Komplexität, Eignung für L-PBF, Relevanz für die entwickelten Prüfverfahren). Um die Datenmenge pro Bauart zu maximieren, entschied sich das Konsortium, die Validierung auf ein einzelnes Objekt zu konzentrieren. Das finale Demonstratorbauteil ist ein Stator Blade, bereitgestellt von GE Additive (Colibrium Additive). Das IAPT brachte insbesondere Expertise zur Eignung des Bauteils für die durchgängige Datenerfassung und KI-gestützte Qualitätsanalyse ein.

Aufbauend auf AP 1.1 wurden die für den Demonstrator relevanten qualitätskritischen Prozessparameter (CTPs) identifiziert – darunter Laserleistung, Scangeschwindigkeit und Schichtstärke –, um deren Einfluss auf die CTQs im Rahmen der Demonstratorbaujobs systematisch untersuchen zu können. Diese bildeten die Grundlage für die Versuchsplanung bei toolcraft. Darüber hinaus erstellte FTTD auf Basis des Stator-Blade-Designs technische Zeichnungen mit Toleranzangaben, die als Input für die GOM-basierte geometrische Auswertung dienten.

KPIs zur quantitativen Bewertung der durch AMalytik erzielten Prozessverbesserungen wurden im Konsortium diskutiert, konnten jedoch aufgrund der begrenzten Anzahl gefertigter Baujobs nicht abschließend mit belastbaren Baselines hinterlegt werden. Die grundsätzliche

Methodik zur KPI-Erhebung – insbesondere die Verknüpfung von Prozessparametern, In-situ-Daten und Qualitätsergebnissen in der zentralen Datenbank – wurde jedoch etabliert.

AP6.2 Qualifizierung der Messverfahren

Der Stand der Entwicklungen der Messverfahren ist den Zwischenberichten von FTTD und Colibrium Additive zu entnehmen. Das Fraunhofer IAPT unterstützte die Entwicklungen durch Beratungen zu typischen Fehlern in der additiven Fertigung sowie der Erarbeitung von Konzepten der Fehlererkennung:

Hinsichtlich der SIR ist es entscheidend zu berücksichtigen, dass nur aneinanderreibende Oberflächen zu einem Signal führen. Sobald also eine Delamination oder ein Riss mit voneinander entfernten Oberflächen existiert, sind diese Defekte zwar zu erkennen, allerdings nur am Startpunkt der Delamination oder des Risses. Ein gemessener Hotspot bedeutet also nicht, dass allein dort sich ein Fehler befindet. Der Fehler als Ganzes kann um ein Vielfaches größer sein.

Hinsichtlich der Messsystems von Colibrium Additive ist ebenfalls die richtige Interpretation des Messsignals von entscheidender Bedeutung. Zum einen bedeutet eine Abweichung vom Sollwert nicht zwangsläufig, dass an dieser Stelle ein Defekt aufgetreten ist. Es gibt einige Möglichkeiten der False-Positive-Bewertung. Beispielsweise können Pulverpartikel aufgewirbelt werden und in das durch den Laserstrahl belichtete Volumen oberhalb der Baufläche fallen, wo sie durch die geringe Wärmekapazität leicht verdampfen können. Dieses Phänomen wird von dem Sensor wegen der starken Strahlung unter Umständen als eine lokale Überhitzung des Schmelzbades interpretiert. Solche Phänomene müssen bei der Dateninterpretation berücksichtigt und, sofern möglich, von den Signalverläufen der echten Fehler getrennt werden. Falls dies nicht möglich ist, muss die Ambivalenz der Signalaussage aufgezeigt werden.

AP6.3 Validierung der digitalen Verkettung und automatisierten Qualitätsdatenverwertung

Die geplante Validierung am Use-Case auf Basis der im Projekt erhobenen Daten war nicht möglich, da die Datenbasis (Anzahl der Baujobs/Proben und Varianz der Einflussgrößen) zu gering ausfiel. Eine statistisch belastbare End-to-End-Bewertung der Prozesskette konnte damit im Projektkontext nicht durchgeführt werden.

Die Machbarkeit des vorgesehenen Ansatzes wurde jedoch im Rahmen von AP 5.4 mit einem Demo-Datensatz nachgewiesen. Die dort genutzte Analysepipeline (Datenaufnahme über die offene API, Vorverarbeitung, automatisierte KI-Auswertung, Visualisierung/Review) ließ sich End-to-End betreiben. In diesem Setup waren sowohl die Erkennung von

Prozessabweichungen als auch die schnelle Auffindung und Lokalisierung von Qualitätsabweichungen im Datensatz nachweisbar.

Aus IAPT-Sicht ist die digitale Verkettung samt automatisierter Qualitätsdatenverwertung somit funktional belegt; für eine abschließende Validierung am industriellen Use-Case ist eine erweiterte und diversere Datenbasis erforderlich.

2. Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Die geleistete Arbeit entspricht den im Projektantrag dargestellten Teilvorhaben.

Die Entwicklungen erforderten viel Entwicklungsarbeit, um eine zufrieden stellende Evaluierung zu ermöglichen.

3. Voraussichtlicher Nutzen

Im Rahmen dieser Projektarbeit wurden wesentliche Grundlagen für eine durchgängige, datengetriebene Qualitätssicherung in der additiven Fertigung gelegt: Mit dem amsight-basierten Qualitätsdatenmodell und Backend (offene API, Code-Umgebung), einem modularen Web-UI sowie definierten Ingestionspfaden (u. a. MQTT) steht eine skalierbare Infrastruktur zur Verfügung, die Prozess-, Sensor- und QS-Daten konsistent verknüpft. KI-basierte Analysepfade (u. a. Random Forest inkl. SHAP-Erklärbarkeit) wurden prototypisch umgesetzt und ermöglichen die Ableitung von Quality Gates. Eine abschließende Validierung am Use-Case war aufgrund der projektintern verfügbaren Datenmenge nicht möglich; die Machbarkeit (Erkennung von Prozess- und Qualitätsabweichungen) wurde mit einem Demo-Datensatz in AP 5.4 nachgewiesen. Die in AP 4.4 erarbeiteten Anforderungen und Konzepte zur digitalen Zertifizierung schaffen die Basis für eine doppelte Rückführbarkeit.

Der Nutzen der entwickelten Lösungen liegt in folgenden Bereichen:

- End-to-end-Rückverfolgbarkeit und schnellere Datenverfügbarkeit entlang der Prozesskette.

- Frühzeitige Detektion von Prozessabweichungen und fokussierte QS durch KI-gestützte Analysen.

- Reduktion von Durchlaufzeiten und Ausschuss durch datenbasierte Quality Gates.

- Vorbereitung zertifizierungskonformer Dokumentation (Integrität/Provenienz; Anschlussfähigkeit an Luftfahrtnachweise).

- Wiederverwendbare Blaupausen für Live-Anbindung und Schnittstellen.

Die konkreten nächsten Schritte sind:

- KPI-Set finalisieren, Baselines erheben und Wirksamkeit bewerten.

- Datensatz erweitern (weitere Baujobs/Varianten) und Domänenwissen fortschreiben (FMEA/CTP-Katalog).

- KI-Pipeline produktiv validieren (Retraining, Monitoring, Unsicherheitsquantifizierung) und in UI-Workflows verankern.

- Digitale Zertifizierung implementieren und auditierbar validieren (Chain-of-Custody, Signaturen/Hashes).

- Live-Ingestion auf L-PBF-Anlagen ausrollen (Security/HA) und Gegenschnittstellen finalisieren.

- Beiträge zur Normung/Standardisierung (Datenmodelle, Zertifizierungsmetadaten) initiieren.

- Gespräche mit Anwendern und Anschlussprojekte (F&E/Industrie) fortführen.

Verwertungsplan (trotz genannter Einschränkungen):

- Qualitätsdatenmodell und amsight-Backend (offene API, UI) Notwendige Weiterentwicklung: Performance-/Security-Härtung; produktive End-to-End-Anbindung inkl. Live-Ingestion; Onboarding-Guides. Zeithorizont: 6- 12 Monate.

- KI-Analysepipeline (Random Forest + SHAP) inkl. Quality Gates Notwendige Weiterentwicklung: Erweiterung/Validierung auf größeren, diverseren Datensatz; Retraining/Drift-Monitoring; Unsicherheitsmaße

Zeithorizont: 12- 24 Monate.

- Ingestion-Blueprint für Live-Daten (Topics/Schemata) Notwendige Weiterentwicklung: Rollout auf weitere Anlagen/Sensoren; Interoperabilität zu OPC UA/Sparkplug B; Betrieb in hochverfügbaren Setups

Zeithorizont: 6- 12 Monate.

- Digitale Zertifizierung (Konzept/Metadatenfelder) Notwendige Weiterentwicklung: Technische Implementierung (Signaturen/Zeitsiegel); auditierbare Validierung; Prozesshandbuch.

Zeithorizont: 12- 18 Monate.

- CTP/CTQ-Wissensbasis (FMEA, Priorisierung) Notwendige Weiterentwicklung: KPI-Set finalisieren; Baselines und Zielwerte definieren; Regeltabellen für operative Anwendung.

Zeithorizont: 6- 9 Monate.

Patente:

- Es wurden keine Patentanmeldungen während der Laufzeit des Verbundprojekts vom Fraunhofer IAPT durchgeführt.

Veröffentlichungs- und Verwertungsmaßnahmen:

- Veröffentlichungen auf Konferenzen und in Journals (Ziel: 3- 5 Konferenzbeiträge, 1- 2 Journal-Paper, 2- 3 Messepräsentationen).

Zeithorizont: bis 2 Jahre nach Projektende

Verantwortlich: IAPT, RWTH/WZL, FTTD, toolcraft, amsight.

- Social-Media-Aktivitäten (insbesondere LinkedIn), regelmäßige Projektupdates

Zeithorizont: während des Projekts und bis 12 Monate nach Projektende

Verantwortlich: IAPT und Partner.

- Abschluss-Event/Abschlusspräsentation mit Stakeholdern

Status: durchgeführt

Verantwortlich: IAPT und Partner.

- Beiträge zur Standardisierung (Datenmodelle, Zertifizierungsmetadaten)

Zeithorizont: innerhalb von 2 Jahren nach Projektende

Verantwortlich: IAPT, RWTH/WZL, FTTD, toolcraft.

Die Social-Media-Aktivitäten wurden planmäßig umgesetzt; die Abschlusspräsentation hat stattgefunden. Die weiteren Maßnahmen werden wie angegeben fortgeführt. Die

Zusammenarbeit mit den Verbundpartnern (FTTD, RWTH/WZL, toolcraft, amsight) wird für Produktentwicklung, Veröffentlichungen und Anschlussprojekte fortgesetzt.

4. Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Dem Konsortium sind folgende Aktivitäten bekannt geworden:

- Voxelgenaue Validierung durch Referenzdatensätze: Die Initiative NIST AM-Bench (2022/2025) stellt den industriellen Goldstandard bereit, indem sie hochauflösende In-situ-Sensordaten (Thermografie) präzise mit 3D-Synchrotron-CT-Aufnahmen korreliert. Dies ermöglicht die exakte Verifizierung von KI-Modellen zur Defekterkennung auf Basis realer physikalischer Messwerte (Quelle: NIST.gov / AM-Bench 2022 & 2025 Datasets).

- Erklärbarkeit der KI (XAI) in der Qualitätssicherung: Die Integration von SHAP-Werten in die AM-Bildverarbeitung erlaubt es heute, KI-Entscheidungen für Zertifizierer transparent zu machen, indem die Korrelation zwischen lokalen Prozessanomalien (z. B. Überhitzung) und der resultierenden Porosität physikalisch begründet wird (Quelle: Additive Manufacturing Journal, Vol. 72, 2023 / Carnegie Mellon University "NextMfg", 2024).

- Maschinenlesbare Zertifizierung und Datenintegrität: Durch das Projekt GEMIMEG-II und die Initiative QI-Digital wurde der Digitale Kalibrierschein (DCC) der PTB für die additive Fertigung einsatzbereit gemacht. Er ermöglicht eine fälschungssichere, kryptografisch signierte Dokumentation der Messmittel- und Prozesskettenintegrität (Quelle: PTB.de / DCC-Spezifikationen 2024 & QI-Digital Whitepaper 2023).

- Standardisierte Interoperabilität für AM-Daten: Mit der Veröffentlichung der OPC UA Companion Specification for Additive Manufacturing (OPC 40301 / VDMA 40011) im Jahr 2024 wurde ein herstellerübergreifendes Informationsmodell etabliert, das den Live-Datenstrom (Status, Parameter, Fehlercodes) von L-PBF-Anlagen für übergeordnete IT-Systeme (MES/Cloud) normiert (Quelle: OPC Foundation / VDMA, Edition 2024).

Weitere Forschungsaktivitäten mit einem vergleichbarem Leistungsspektrum wie das durchgeführte Projekt “AMalytik” sind derzeit nicht bekannt.

Veröffentlichungen des Ergebnisses nach Nr. 5 der NKBF/NABF

Im Rahmen des Projektes wurden die folgenden Veröffentlichungen von den folgenden Partnern durchgeführt bzw. sind noch geplant:

Fraunhofer IAPT

Veröffentlichungen

- *Darstellung der Zwischenergebnisse auf der Formnext 2025*
- *LinkedIn-Post*

Geplante Veröffentlichungen

- *ein weiterer LinkedIn-Post*

- *Paper in "Additive Manufacturing"*

Literaturverzeichnis

Boos, D. D. (2003). Introduction to the Bootstrap World. Statistical Science, 18(2). https://doi.org/10.1214/ss/1063994971

Chernick, M. R., González-Manteiga, W., Crujeiras, R. M. & Barrios, E. B. (2011). Bootstrap Methods. In M. Lovric (Hrsg.), International Encyclopedia of Statistical Science (S. 169–174). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-04898-2_150

DIN Deutsches Institut für Normung e. V. (12.2023). DIN EN ISO/ASTM 52920: Additive Fertigung - Grundsätze der Qualifizierung - Anforderungen an industrielle additive Fertigungsverfahren und Produktionsstätten (52920). Beuth Verlag GmbH.

European Cooperation for Space Standardization (30. Juli 2021). ECSS-Q-ST-70-80C: Space product assurance: Processing and quality assurance requirements for metallic powder. ESA Requirements and Standards Section.

Hermann, F., Michalowski, A., Brünnette, T., Reimann, P., Vogt, S. & Graf, T. (2023). Data-Driven Prediction and Uncertainty Quantification of Process Parameters for Directed Energy Deposition. Materials, 16(23), 7308. https://doi.org/10.3390/ma16237308

Kemper, A. H. & Eickler, A. (2015). Datenbanksysteme: Eine Einführung (10., erweiterte und aktualisierte Auflage). De Gruyter Oldenbourg Studium. De Gruyter Studium.

Lafrentz, N. (2018). Six-Sigma-Ansatz zur industriellen Qualifikation der additiven Fertigung am Beispiel des L-PBF-Prozess [Masterarbeit]. Technische Universität Hamburg, Hamburg.

Michael Falk, Frank Marohn, Bernward Tewes, Maria Macke & R Michel. (2012). A First Course on Time Series Analysis with SAS: Ein Open-Source Projekt.

Munsch, M., Schmidt-Lehr, M., Wycisk, E. & Führer, T. (2023). AMPOWER Report 2023: Additive Manufacturing Market Report.

Pereira Parente, A., Souza Jr., M. B. de, Valdman, A. & Mattos Folly, R. O. (2019). Data Augmentation Applied to Machine Learning-Based Monitoring of a Pulp and Paper Process. Processes, 7(12), 958. https://doi.org/10.3390/pr7120958

Rehme, O. (2010). Cellular Design for Laser Freeform Fabrication (1. Aufl.). Schriftenreihe Lasertechnik: Bd. 4. Cuvillier Verlag.

Thomopoulos, N. T. (2013). Essentials of Monte Carlo simulation: Statistical methods for building simulation models (1st ed.). Springer.

Yu, C. H. (2002). Resampling methods: Concepts, Applications, and Justification. Practical Assessment, Research, and Evaluation, 8(1). https://doi.org/10.7275/9cms-my97